

UNIVERSIDADE FEDERAL DO PARANÁ

FERNANDO MUCIO BANDO

ANÁLISE *FUZZY* DE ÁRVORE DE FALHAS NA GESTÃO DE SEGURANÇA DE
BARRAGENS – BLOCO D38 DA BARRAGEM DE ITAIPU

CURITIBA

2016

FERNANDO MUCIO BANDO

ANÁLISE *FUZZY* DE ÁRVORE DE FALHAS NA GESTÃO DE SEGURANÇA DE
BARRAGENS – BLOCO D38 DA BARRAGEM DE ITAIPU

Tese apresentada como requisito parcial à obtenção do grau de Doutor em Métodos Numéricos em Engenharia, ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Setor de Tecnologia de Ciências Exatas da Universidade Federal do Paraná, na área de concentração de Programação Matemática, na linha de pesquisa em Métodos Estatísticos Aplicados à Engenharia.

Orientador: Dr. Jair Mendes Marques

CURITIBA
2016

Bando, Fernando Mucio

Análise fuzzy de árvore de falhas na gestão de segurança de barragens – bloco D38 da barragem de Itaipu / Fernando Mucio Bando. – Curitiba, 2016.

148 f. : il.

Tese (doutorado) – Universidade Federal do Paraná, Setores de Tecnologia e de Ciências Exatas, Programa de Pós-Graduação em Métodos Numéricos em Engenharia.

Orientador: Jair Mendes Marques

Bibliografia: p. 131-137

1. Barragens e açúdes - Segurança. 2. Redes neurais (Computação). 3. Algoritmos. I. Marques, Jair Mendes. II. Título.

CDD 627.8



Ministério da Educação
Universidade Federal do Paraná
Setor de Tecnologia / Setor de Ciências Exatas
Departamento de Construção Civil / Departamento de Matemática/ Departamento
de Engenharia de Produção
Programa de Pós-Graduação em Métodos Numéricos em Engenharia -
PPGMNE/UFPR.



ATA DE SESSÃO PÚBLICA DE DEFESA DE TESE PARA A OBTENÇÃO DO GRAU DE DOUTOR EM MÉTODOS NUMÉRICOS EM ENGENHARIA

No dia treze de Maio de dois mil e dezesseis, às 09h30min, na Sala de Vídeo Conferência, CESEC/TC/UFPR - Centro Politécnico - Setor de Tecnologia da Universidade Federal do Paraná, foram instalados os trabalhos de arguição do doutorando **FERNANDO MUCIO BANDO** para a Defesa Pública de sua Tese intitulada: "*Análise Fuzzy de Árvore de Falhas na Gestão de Segurança de Barragens - Bloco D38 da Barragem de Itaipu*". A Banca Examinadora, designada pelo Colegiado do Programa de Pós-Graduação em MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná, foi constituída pelos seguintes Membros: JAIR MENDES MARQUES (UFPR), ANSELMO CHAVES NETO (UFPR), JOSIELE PATIAS (FPTI), MAURICIO KOUBAY DO AMARAL (UTFPR), VOLMIR EUGÊNIO WILHELM (UFPR). Dando início à sessão, a presidência passou a palavra ao discente, para que o mesmo expusesse seu trabalho aos presentes. Em seguida, a presidência passou a palavra a cada um dos Examinadores, para suas respectivas arguições. O aluno respondeu a cada um dos arguidores. A presidência retomou a palavra para suas considerações finais e, depois, solicitou que os presentes e o doutorando deixassem a sala. A Banca Examinadora, então, reuniu-se sigilosamente e, após a discussão de suas avaliações, decidiu-se pela APROVAÇÃO do aluno. O doutorando foi convidado a ingressar novamente na sala, bem como os demais assistentes, após o que a presidência fez a leitura do Parecer da Banca Examinadora. Nada mais havendo a tratar a presidência deu por encerrada a sessão, da qual eu, JAIR MENDES MARQUES, lavrei a presente ata, que vai assinada por mim e pelos membros da Comissão Examinadora.

Curitiba, 13 de Maio de 2016.


Prof JAIR MENDES MARQUES

Presidente da Banca Examinadora (UFPR)


Prof ANSELMO CHAVES NETO

Avaliador Interno (UFPR)


Prof MAURICIO KOUBAY DO AMARAL

Avaliador Externo (UTFPR)


Prof VOLMIR EUGÊNIO WILHELM

Avaliador Interno (UFPR)


Prof.ª JOSIELE PATIAS

Avaliadora Externa (ITAIPU)



Dedico esse trabalho aos meus Pais, Cidão e Dona Cida,
que muito me ensinaram e apoiaram. À minha esposa Dani e o nosso filho João
Victor, pela paciência, pelo incentivo, pelo carinho e principalmente pelo amor que
me inspiram.

AGRADECIMENTOS

No meu entender, nunca realizamos um trabalho solitário pois sempre somos auxiliados, seja com ideias, com compreensão, com conselhos ou simplesmente com o silêncio caridoso. Na realização deste trabalho tive muitos colaboradores e recebi diversos apoios, e é com alegria que agradeço:

Ao Prof. Dr. Jair Mendes Marques pelo trabalho de orientação e por ter confiado em mim, respeitando integralmente o meu modo de pensar.

À engenheira civil da Itaipu, Dra. Josiele Patias, pelos proveitosos conselhos, incentivos, ideias sugeridas para a realização desta tese e pela amizade que pude contar durante todo o trabalho.

À Universidade Estadual do Oeste do Paraná – Unioeste, por viabilizar o desenvolvimento deste trabalho através do afastamento remunerado das minhas atividades.

À Fundação Araucária pelo apoio financeiro.

Ao Centro de Estudos Avançados em Segurança de Barragens – CEASB, a Fundação Parque Tecnológico de Itaipu – PTI e a Itaipu Binacional pelo suporte técnico e fornecimento dos dados.

Ao Programa de Pós-graduação em Métodos Numéricos em Engenharia da UFPR pelo suporte teórico para o desenvolvimento deste estudo.

Aos professores que desempenharam com dedicação as aulas ministradas, em especial a Profa. Dra. Liliana Madalena Gramani e o Prof. Dr. Anselmo Chaves Neto pelos esforços dedicados para a realização do Dinter.

Aos companheiros de turma que fizeram desse período uma acolhedora e divertida convivência, com certeza, sem vocês tudo seria mais complicado. Em

especial, gostaria de agradecer o amigo Geraldo Brito, por idealizar, acreditar e se empenhar para a realização do doutorado.

À minha família por me acolher sempre que precisei e pelo estímulo constante.

Ao pessoal do futebol de sábado por ajudar a diminuir a pressão com os inúmeros momentos de descontração.

Ao povo do Estado do Paraná que ‘financiou’ meu afastamento e é quem, em última instância, permite a realização deste trabalho.

E principalmente à Deus por estar sempre presente em minha vida e por ter novamente me proporcionado a oportunidade de chegar até aqui.

Desistir...eu já pensei seriamente nisso, mas nunca me levei realmente a sério; é que tem mais chão nos meus olhos do que o cansaço nas minhas pernas, mais esperança nos meus passos, do que tristeza nos meus ombros, mais estrada no meu coração do que medo na minha cabeça.

Cora Coralina

RESUMO

As construções de usinas hidrelétricas consistem em empreendimentos de grande relevância para o desenvolvimento econômico e social de um país. No entanto, esse é um tipo de obra que requer muita vigilância, pois a ocorrência de comportamentos anormais em sua estrutura podem resultar em consequências indesejáveis. Inspeções realizadas através de instrumentos de monitoramento é um dos mecanismos de avaliação da segurança de uma barragem. Leituras periódicas dos instrumentos geram conjuntos de dados estocásticos que fornecem importantes informações sobre sua saúde estrutural. Métodos matemáticos e estatísticos são de grande importância para o tratamento e análise dos dados, pois, possibilitam previsões de possíveis anormalidades no comportamento da barragem. Assim, este trabalho propõe uma metodologia de análise de árvore de falhas, em que o conceito de falha é definido através da detecção e classificação automática de pontos de mudança no comportamento de séries temporais geradas por instrumentos de monitoramento instalados em uma barragem. A detecção automática dos pontos de mudança em uma série temporal consiste em uma abordagem neuro/fuzzy/bayesiana dividida em três etapas: clusterização dos pontos da série temporal a partir de um mapa auto-organizável de Kohonen; construção de um conjunto *fuzzy* que transforma a série temporal inicial, com distribuição arbitrária, em uma nova série com distribuição de probabilidade beta; a detecção dos pontos de mudança através de uma simulação de Monte Carlo via algoritmo de Metropolis-Hastings. O método para a classificação dos pontos de mudança detectados, em relação aos níveis de alerta, foi desenvolvido através da construção de um sistema de controle *fuzzy* baseado em informações subjetivas utilizadas por especialistas em segurança da barragem. Por fim, a proposta metodológica é aplicada em dados gerados por instrumentos de monitoramento instalados no bloco de contraforte D38, da estrutura de barramento da Usina Hidrelétrica de Itaipu, onde o método destacou como principal resultado a detecção da mudança e comportamento nas medidas dos instrumentos de monitoramento ocorridas no período de enchimento do reservatório, o que mostra a eficiência dos conceitos abordados. Assim, pode-se concluir que a análise *fuzzy* de árvore de falhas descrita neste trabalho pode ser considerada uma boa alternativa para o auxílio no gerenciamento da segurança de uma barragem.

Palavras-chave: Segurança de Barragem, Análise de Árvore de Falhas, Redes de Kohonen, Conjuntos *Fuzzy*, Algoritmo de Metropolis-Hastings, Controlador *Fuzzy*, Medida de Importância.

ABSTRACT

The construction of hydroelectric plants consist of highly relevant projects for economic and social development of a country. However, this is a kind of work which requires a lot of monitoring, because the occurrence of atypical behavior in structure can result in undesirable consequences. Inspections carried out by monitoring instruments is one of the safety assessment mechanisms of a dam. Periodic readings of the instruments generate sets of stochastic data provide important information about their structural health. Mathematical and statistical methods are of great importance for the processing and analysis of data therefore enable predictions of possible abnormalities in the dam behavior. Thus, this paper proposes a fault tree analysis methodology, in which the concept of failure is defined by detecting and automatic shift points classification in the time series behavior generated by monitoring instruments installed in a dam. Automatic detection of change points in a time series consists of a neuro/fuzzy/bayesian approach divided into three steps: clustering of points in the time series from a self-organizing map of Kohonen; construction of a fuzzy set that transforms the initial time series with arbitrary distribution on a new series with beta probability distribution; detection of change points through a Monte Carlo simulation via Metropolis-Hastings algorithm. The method for classification of detected shift points in relation to alert levels, is developed by building a fuzzy control system based on subjective information used for dam safety experts. Finally, the proposed methodology is applied to data generated by monitoring instruments installed on the buttress block D38, the bus structure of Itaipu Hydroelectric Power Plant, where the method highlighted as main result the detection of change and behavior in measures of instruments monitoring occurred in the filling period of the container, which shows the efficiency of the discussed concepts. Thus, it can be concluded that the fuzzy analysis of fault tree described in this work could be a good alternative for assistance in security management of a dam.

Key-words: Dam Safety, Fault Tree Analysis, Kohonen Networks, Fuzzy Sets, Metropolis-Hastings algorithm, Fuzzy Controller, Importance Measure.

LISTA DE FIGURAS

FIGURA 2.1 - Formas de desinstabilização em uma barragens de concreto	23
FIGURA 2.2 - Vista da barragem de Itaipu com vertedouro em operação	26
FIGURA 2.3 - Configuração das estruturas da barragem de Itaipu	27
FIGURA 2.4 - Distribuição da instrumentação nas estruturas de concreto de Itaipu	29
FIGURA 2.5 - Tipos de Falhas	31
FIGURA 2.6 - Técnica de janela deslizante	33
FIGURA 2.7 - Estrutura do nó básico do SOM	35
FIGURA 2.8 - Exemplo de uma rede SOM bidimensional	35
FIGURA 2.9 - Número <i>fuzzy</i> triangular	43
FIGURA 2.10 - Número <i>fuzzy</i> trapezoidal	44
FIGURA 2.11 - Número <i>fuzzy</i> forma-S	44
FIGURA 2.12 - Número <i>fuzzy</i> forma-Z	45
FIGURA 2.13 - Esquema geral de um controlador <i>fuzzy</i>	53
FIGURA 2.14 - Exemplo de um diagrama de árvore de falhas	66
FIGURA 3.1 - Distribuição por anos do número de publicações de artigos com o tema " <i>Fuzzy Fault Tree</i> " na Scopus	76
FIGURA 4.1 - Instrumentos do Bloco D38	87
FIGURA 4.2 - Fluxograma da metodologia proposta	90
FIGURA 4.3 - Árvore de falhas do bloco D38 da barragem de Itaipu	92
FIGURA 4.4 - Passos da metodologia para a detecção de ponto de mudança em série temporal	96
FIGURA 5.1 - Séries temporais após o tratamento dos dados	119
FIGURA 5.2 - Pontos de mudança de comportamento detectados	121
FIGURA 5.3 - Passo da construção do controlador <i>fuzzy</i> via pacote FUZZY LOGIC TOOLBOX do software MATLAB R2013A	124
FIGURA 5.4 - Resultado do método de classificação via controlador <i>fuzzy</i>	126
FIGURA 5.5 - Resultado da análise de árvore de falhas do bloco D38 da barragem de Itaipu	128

FIGURA 6.1 - Árvore de Falhas construída por especialistas em segurança de barragens para o bloco de contraforte D38 da Barragem de Itaipu.. 148

SUMÁRIO

1	INTRODUÇÃO	14
1.1	O PROBLEMA.....	14
1.2	OBJETIVO	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivos Específicos	18
1.3	JUSTIFICATIVA	19
1.4	ESTRUTURA DO TEXTO	19
2	REVISÃO DOS FUNDAMENTOS TEÓRICOS	21
2.1	SEGURANÇA DE BARRAGENS	21
2.2	INSTRUMENTOS DE MONITORAMENTO	23
2.3	SEGURANÇA DA BARRAGEM DE ITAIPU	25
2.4	DETECÇÃO DE FALHAS.....	30
2.5	MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN.....	32
2.6	CONJUNTOS <i>FUZZY</i>	38
2.6.1	Operações entre Conjuntos <i>Fuzzy</i>	40
2.6.2	Números <i>Fuzzy</i>	41
2.6.3	Relações <i>Fuzzy</i>	46
2.7	LÓGICA <i>FUZZY</i>	47
2.7.1	Conectivos Básicos da Lógica <i>Fuzzy</i>	47
2.7.2	Sistemas <i>Fuzzy</i>	49
2.7.3	Controladores <i>Fuzzy</i>	51
2.7.4	Método de Inferência de Mamdani	53
2.7.5	Medida de Possibilidade.....	54
2.8	INFERÊNCIA BAYESIANA	57
2.8.1	Teorema de Bayes	57
2.8.2	Simulação Monte Carlo	58
2.8.3	Cadeias de Markov	61
2.8.4	Algoritmos de Metropolis-Hastings	62
2.9	ÁRVORE DE FALHAS	63

2.9.1	Características de uma Árvore de Falhas	64
2.9.2	Elementos de uma Árvore de Falhas	65
2.9.3	Análise Qualitativa	67
2.9.4	Conjunto de Cortes Mínimos	67
2.9.5	Análise Quantitativa	69
2.9.6	Medidas de Importância	72
3	REVISÃO DE LITERATURA.....	74
3.1	ANÁLISE <i>FUZZY</i> DE ÁRVORE DE FALHAS (FFTA)	74
3.2	MOTIVAÇÃO PARA O USO DA FFTA	74
3.3	PROBABILIDADE <i>FUZZY</i>	77
3.4	USO DE VARIÁVEIS LINGUÍSTICAS.....	78
3.5	OPERADORES <i>FUZZY</i>	79
3.6	MEDIDAS DE IMPORTÂNCIA <i>FUZZY</i>	81
3.7	ANÁLISE DE INCERTEZAS	82
3.8	APLICAÇÃO DA MEDIDA DE POSSIBILIDADE	83
3.9	COMPARAÇÃO ENTRE FTA E FFTA	84
4	MATERIAL E MÉTODOS	86
4.1	MATERIAL	86
4.2	METODOLOGIA	90
4.2.1	Árvore de Falhas do Bloco D38 da Barragem de Itaipu	91
4.2.2	Análise Qualitativa da Árvore de Falhas	93
4.2.3	Tratamento dos Dados.....	95
4.2.4	Detecção de Ponto de Mudança em Série Temporal	96
4.2.5	Técnica de Janela Deslizante	103
4.2.6	Sistema de Controle <i>Fuzzy</i>	104
4.2.7	Classificação do Nível de Alerta para os Pontos de Mudanças	113
4.2.8	Análise <i>Fuzzy</i> de Árvore de Falhas	114
4.2.9	Medida de Importância	115
5	RESULTADOS.....	117
6	CONCLUSÃO	130
	REFERÊNCIAS.....	131
	APÊNDICES.....	138

APÊNDICE 1: ALGORITMO DE TRATAMENTO DOS DADOS.....	138
APÊNDICE 2: ALGORITMO DA REDE DE KOHONEN	139
APÊNDICE 3: ALGORITMO PARA A FUZZIFICAÇÃO DA SÉRIE	
TEMPORAL	140
APÊNDICE 4: ALGORITMO METROPOLIS-HASTINGS	141
APÊNDICE 5: ALGORITMO PARA A TÉCNICA DE JANELA DESLIZANTE	142
APÊNDICE 6: ALGORITMO DE CLASSIFICAÇÃO VIA CONTROLADOR	
FUZZY	143
APÊNDICE 7: ALGORITMO PARA A ANÁLISE FUZZY DE ÁRVORE DE	
FALHAS.....	145
APÊNDICE 8: ALGORITMO PARA O CÁLCULO DA MEDIDA DE	
IMPORTÂNCIA	146
ANEXO	148
ANEXO 1: ÁRVORE DE FALHAS DO BLOCO D38 DA BARRAGEM	
DE ITAIPU	148

1 INTRODUÇÃO

1.1 O PROBLEMA

Uma usina hidrelétrica consiste em um empreendimento de grande relevância para o desenvolvimento econômico e social de um país e a sua manutenção demanda grande capacidade da engenharia, na qual requer-se o envolvimento de profissionais de alta capacidade técnica. No tocante a estrutura de uma barragem, a ocorrência de comportamentos estocásticos (ou aleatórios) podem resultar em consequências indesejáveis a níveis econômicos, ambientais e na segurança de pessoas (ICOLD, 2003).

Em todo o cenário mundial, o tema segurança de barragens consiste em um assunto amplamente debatido. Em outubro de 2002, o banco mundial publicou o livro *Regulatory frameworks for dam safety: A comparative study*, contendo modelo de regulamento, operação, manutenção e inspeção de barragens. Nesse documento, o significado de segurança de barragens engloba fatores que contribuem para a operação como a segurança da estrutura e as obras complementares, o risco potencial para a vida humana, aspectos sanitários e de saúde pública, danos a propriedades e proteção da área no entorno do reservatório. Nessa obra a segurança tem a ver com a operação adequada, manutenção, inspeção e planos de emergência para lidar com situações de risco ao meio ambiente, assim como definição das medidas mitigadoras dos impactos ambientais.

Os responsáveis pelas barragens brasileiras têm-se mostrados preocupados com a saúde de suas barragens. Segundo o IE (Instituto de Engenharia), anualmente, muitas barragens rompem no país, e destaca que em reunião técnica realizada na ANA (Agência Nacional de Águas), horas antes da tragédia da barragem de Algodões no Piauí em 2009, falou-se em 800 acidentes ou incidentes com barragens brasileiras nos últimos oito anos. Ou seja, em média, a cada três ou quatro dias, uma barragem apresenta graves problemas no Brasil (SAYÃO, 2015).

O 3º Simpósio de Segurança de Barragens realizado nos dias 18 e 19 de novembro de 2008 em Salvador, teve como tema principal “Barragens

Contemporâneas: Conhecimento, Durabilidade, Riscos e Falhas”. Nesse evento foram discutidos os acidentes ocorridos em barragens nos últimos 50 anos, fato que ocasionou a busca de providências como elaboração de manuais de inspeção e segurança, análises refinadas por processos computacionais, uso de sistemas remotos de auscultação, análises de riscos e implementação de planos emergenciais.

Em 20 de setembro de 2010 entrou em vigor a lei nº. 12.334 (BRASIL, 2010), que estabelece a Política Nacional de Segurança de Barragens destinadas à acumulação de água para quaisquer usos, a disposição final ou temporária de rejeitos e à acumulação de resíduos industriais, e criou o Sistema Nacional de Informações sobre Segurança de Barragens (SNISB). No art. 2º item III dessa lei a segurança de barragens é definida como sendo a providência de condições que vise a manter a sua integridade estrutural e operacional e a preservação da vida, da saúde, da propriedade e do meio ambiente.

Em seguida veio a resolução nº. 144 de 10 de julho de 2012, que estabelece diretrizes para implantação da política nacional de segurança de barragens, aplicação de seus instrumentos e atuação do sistema nacional de informação sobre segurança de barragens, em atendimento ao artigo 20 da lei nº. 12.334 mencionada anteriormente.

Atualmente, as empresas responsáveis por barragens brasileiras adotam políticas de segurança baseadas nessas leis, de maneira a monitorar a segurança através de um sistema de instrumentação instalado em pontos estratégicos da barragem, o que permite amplo acompanhamento da saúde estrutural da barragem, diante da ocorrência de diversos eventos aleatórios (temperatura ambiente e da água, nível do reservatório, variação pluviométrica).

Considerada uma das maiores usinas hidrelétricas mundial, Itaipu Binacional é uma importante referência em segurança de barragens. Em função da sua binacionalidade, a empresa está isenta das obrigações das leis nacionais citadas anteriormente, mas segundo Neumann Jr *et al.* (2011), a Itaipu procura adequar alguns de seus procedimentos, alinhando suas ações à legislação, além de reforçar sua colaboração com o tema disponibilizando seu *know-how* às entidades nacionais e internacionais interessadas.

Desse modo, a Itaipu possui atualmente cerca de 2.792 instrumentos de monitoramento instalados, dos quais, foram selecionados por volta de 270, considerados mais importantes, que receberam um sistema de aquisição automática de dados, e que têm o objetivo de supervisionar o comportamento da barragem. Esses

instrumentos possibilitam leituras com uma frequência parametrizável de 5 a 30 minutos, esses valores são processados, armazenados e transmitidos para uma estação central, que é responsável pelo tratamento dos dados envolvendo análises, comparações e acionamento de alarmes (ITAIPU, 2008). Com esse volume de dados armazenados diariamente, a construção de métodos computacionais capazes de descreverem os fenômenos medidos pelos instrumentos é de enorme importância para o gerenciamento da segurança de uma barragem, melhorando o desempenho na tomada de decisões e possibilitando a definição de alertas automatizados.

Existem várias técnicas de análise de riscos que permitem detectar mudanças no comportamento em sistemas complexos compostos de uma quantidade elevada de variáveis. Uma metodologia importante é a Análise de Árvore de Falhas (FTA – *Fault Tree Analysis*) (U. S. NUCLEAR REGULATORY COMMISSION, 1981). Esta técnica tem se mostrado eficiente pois permite através de uma representação de fácil interpretação, reconhecer e ponderar quais os principais eventos que possam contribuir para a ocorrência de falhas, tornando-se uma importante técnica de auxílio ao setor responsável pela segurança do sistema (NASA, 2002).

Os conceitos e as técnicas utilizadas na análise de árvore de falhas continuam a ser desenvolvidas, e hoje é considerada como uma metodologia estabelecida para os estudos de segurança e confiabilidade de diversos sistemas, inclusive em segurança de barragens. A Usina de Itaipu trabalha com Árvores de Falhas que modelam eventos indesejáveis em bloco-chaves de sua barragem, porém, ainda não são totalmente baseadas nas informações numéricas geradas pelos alguns instrumentos de monitoramento, isso ocorre devido a diversos fatos, entre eles, incertezas envolvidas na definição de falha, pois, a quantidade de amostra de um evento indesejável é muito baixa ou até mesmo inexistente (DESHPANDE, 2011).

Apesar das diversas incertezas envolvidas na definição de falha, a elevada experiência de especialistas em segurança de barragem, proporciona um amplo banco de informações que possibilita análises qualitativas sobre o comportamento da estrutura através de observações feitas sobre as medidas geradas pelos instrumentos de monitoramento. Muitas vezes, essa classificação da normalidade no comportamento da barragem, baseada em experiência, é feita através de termos linguísticos como “normal”, “baixo”, “muito elevado”. Desse modo, teorias que permitam modelar e adaptar matematicamente os termos subjetivos encontrados nesse banco de conhecimento gerado por anos de experiência, possibilitam o desenvolvimento de

metodologias capazes de classificar automaticamente as possíveis anomalias no comportamento dos instrumentos, padronizando e auxiliando no gerenciamento da segurança da barragem.

A teoria de conjunto *fuzzy* foi introduzida em 1965 pelo matemático Lotfi Asker Zadeh (ZADEH, 1965) com o objetivo de tratar termos subjetivos com formalismo matemático, sendo considerado um dos primeiros passos no sentido de se programar e armazenar conceitos vagos em computadores, tornando possível a produção de cálculos com informações imprecisas, baseada na forma que é feita pelo ser humano (BARROS; BASSANEZI, 2010).

A teoria de conjuntos *fuzzy*, tem crescido consideravelmente, tanto do ponto de vista teórico como nas aplicações em diversas áreas de estudo, inclusive na área de controle da segurança de sistemas complexos (ZIMMERMANN, 2010). Na década de oitenta, Tanaka *et al.* (1983) aliaram a análise de árvore de falhas com a teoria de conjuntos *fuzzy* apresentando uma nova metodologia denotada por análise *fuzzy* de árvore de falhas (FFTA - *Fuzzy Fault Tree Analysis*). Essa metodologia tem garantido bons resultados no estudo de falhas em sistemas complexos, onde o conceito de falha envolve incertezas em sua definição, devido ao baixo número de casos de ocorrência de eventos indesejáveis (DESHPANDE, 2011).

A detecção de uma possível falha através da leitura de dados gerados por instrumentos de monitoramento é muitas vezes iniciada pela identificação visual de uma alteração no comportamento da série temporal gerada pelos dados de um instrumento. A partir dessa identificação, a alteração é analisada pelo especialista usando conhecimento e experiência para determinar o nível de atenção que será dado para essa mudança do comportamento da série temporal.

Na literatura especializada, existem alguns métodos numéricos para a detecção automática de pontos de mudanças em séries temporais, por exemplo (HINKEY, 1971), (BARRY; HARTIGAN, 1993) e (LOSCHI; CRUZ, 2005). Sistemas de supervisão aplicados a detecção de falhas são denominados por FDI (*Fault Detection and Isolation*), esses sistemas servem para reconhecer os comportamentos anormais dos componentes de um processo. Porém, em geral as técnicas de FDI dependem de algum conhecimento *a priori* do comportamento da série temporal, como modelos estatísticos. Entre estas técnicas pode-se destacar: observador de Luenberger, filtro de Kalman, redes neurais artificiais e redes neuro-*fuzzy*.

Em algumas séries temporais, não é possível o conhecimento *a priori* necessário para aplicar as técnicas citadas. Um estudo atual que tenta contornar esta situação é apresentada no trabalho D'Angelo (2010), onde o autor propõe uma formulação neuro/fuzzy/bayesiana para a detecção de ponto de mudança em séries temporais que permite a detecção de falhas em um sistema, sem a necessidade de um modelo matemático, estudo de resíduos ou geração de padrões.

1.2 OBJETIVO

1.2.1 Objetivo Geral

A proposta desse trabalho é combinar dados numéricos gerados por instrumentos de monitoramento com informações obtidas pela experiência de especialistas na área de segurança de barragens, para desenvolver uma metodologia que permita a análise de árvore de falhas, utilizando técnicas neuro/fuzzy/bayesiana e controladores *fuzzy* para a detecção e classificação automática de pontos de mudança em séries temporais.

1.2.2 Objetivos Específicos

Para a conclusão do objetivo geral, é necessário a realização dos seguintes objetivos específicos:

- Tratamento estatístico dos dados fornecidos pela Itaipu;
- Desenvolvimento do método de detecção automática de pontos de mudança em séries temporais;
- Determinação da correlação entre grandezas externas e medidas geradas por instrumentos de monitoramento da Itaipu;
- Construção de um controlador *fuzzy* para a classificação dos pontos de mudanças detectados, em relação a um nível de alerta;

- Análise qualitativa da árvore de falhas utilizada pela Itaipu;
- Análise quantitativa da árvore de falhas utilizada pela Itaipu, através de conceitos da lógica *fuzzy*;
- Determinação de um valor numérico que representa as condições do bloco D38 da barragem de Itaipu em relação as variações semanais medidas nos instrumentos de monitoramento;
- Determinação dos instrumentos que mais colaboram para uma vulnerabilidade da segurança do bloco D38;
- Implementação computacional do método proposto.

1.3 JUSTIFICATIVA

O monitoramento adequado de uma barragem do porte de Itaipu exige muitos instrumentos, isto gera um gigantesco banco de dados dos registros. Para que esses registros apresentem a real característica da segurança do bloco, é de extrema necessidade uma metodologia que possibilite o tratamento automático dos dados. Assim, com esse intuito é que a metodologia deste trabalho foi desenvolvida. Um mecanismo de detecção de falha é de grande valia, pois auxilia na gestão da segurança e possibilita um melhor entendimento do sistema, permitindo estimar valores numéricos que representem a “saúde” da estrutura.

1.4 ESTRUTURA DO TEXTO

O texto seguirá a seguinte organização: o segundo capítulo apresenta uma revisão dos conceitos e técnicas que são utilizados no desenvolvimento do trabalho. O terceiro capítulo descreve uma revisão do desenvolvimento científico da área de análise *fuzzy* de árvore de falhas, apresentando a crescente atenção dada pelos pesquisadores nesse campo de pesquisa e suas contribuições. O quarto capítulo apresenta os materiais e métodos utilizados. No quinto capítulo são discutidos os resultados obtidos pela aplicação da proposta metodológica nos dados gerados por instrumentos de

monitoramento instalados no bloco de contraforte D38 da barragem de Itaipu. E por fim, o sexto capítulo descreve as conclusões finais relativas ao trabalho.

2 REVISÃO DOS FUNDAMENTOS TEÓRICOS

2.1 SEGURANÇA DE BARRAGENS

O conceito de Segurança de Barragens pode ser definido como sendo a providência de condições que vise manter a integridade estrutural e operacional da barragem e a preservação da vida, da saúde, da propriedade e do meio ambiente (BRASIL, 2010). Desse modo, a segurança de uma barragem está intimamente relacionada aos seus aspectos de projeto, construção, operação, manutenção, inspeção e instrumentação, determinando o modo que cada um desses itens devem ser tratados e verificando as suas inter-relações com a barragem e sua fundação (CBGB, 1996).

Segundo o Comitê Brasileiro de Barragens - CBDB (2005), o controle da segurança de uma barragem exige os dois seguintes procedimentos: (i) inspeções visuais periódicas das superfícies expostas e acessíveis da barragem, da fundação, das galerias, das obras anexas e do reservatório, (ii) monitoramento sistemático da barragem e da sua fundação por meio de instrumentos instalados na barragem para avaliar a segurança da obra.

As principais atividades relacionadas com o monitoramento de uma barragem são:

- A execução das medições por meio da instrumentação;
- A coleta e a verificação dos dados;
- Análise dos dados;
- A interpretação e a apresentação dos resultados.

Assim, o principal objetivo do monitoramento de uma barragem é a obtenção de informações destinadas a avaliar, de maneira contínua, o comportamento e a segurança da barragem (SILVEIRA, 2003). Durante a operação, o monitoramento visa dois objetivos específicos:

- Monitoramento a curto prazo: detecção de mudanças a curto prazo (anomalias) no comportamento e o estado da barragem e do reservatório, podendo afetar a segurança, as condições de operações e necessitar ações imediatas, por

exemplo, restrições na operação, reparos, ou (em situações excepcionais) disparo de alarme.

- Monitoramento a longo prazo: detecção de mudanças a longo prazo (fenômenos eventuais de deterioração) no estado e o comportamento em vista de efetuar uma avaliação completa e aprofundada da segurança da barragem e do reservatório (incluindo a verificação dos parâmetros de projeto), o que pode demonstrar a necessidade, em certos casos, de executar trabalhos de manutenção.

A segurança de uma barragem e da população a jusante depende não somente da qualidade do projeto e de sua construção, mas também de uma perfeita manutenção durante a operação assim como de uma eficiente auscultação para controlar o comportamento da barragem (CBDB, 2005).

Em geral, um sistema de instrumentos de monitoramento de barragem de concreto segue a norma NBR 8681 – Ações e Segurança das Estruturas (ABNT, 2003), que estabelece as verificações necessárias correspondentes à análise de estabilidade de uma barragem de concreto, visando avaliar a segurança quanto aos movimentos: deslizamento, tombamento, flutuação, tensões na base da fundação e na estrutura, deformações, recalques e vibrações (SILVEIRA, 2003).

Do ponto de vista físico, tais movimentos ocorrem pelo fato de que a diferença de nível de água gera um gradiente hidráulico entre montante e jusante da barragem, fazendo com que a água do reservatório queira passar para a jusante buscando o equilíbrio hidráulico. Para tal, a água percola principalmente através do maciço de fundação da barragem. Durante este processo, a água infiltrada gera forças verticais que atuam de baixo para cima sob a barragem, denominadas subpressões na fundação (denotado por $F_{\text{subpressão}}$ na FIGURA 2.1). Além disso, a água do reservatório gera forças horizontais que atuam de montante à jusante sobre a barragem, denominadas pressões hidrostáticas contra a parede da barragem (denotado por $F_{\text{reservatório}}$ na FIGURA 2.1). Estes dois tipos principais de solicitação são referidas como forças desestabilizadoras, que combinadas podem acarretar o tombamento ou deslizamento da barragem (FIGURA 2.1). Isso ocorre também pelos esforços e momentos diretamente aplicados quanto pelo alívio de peso próprio da estrutura (denotado por P na FIGURA 2.1) (VILLWOCK, 2009).




FIGURA 2.1 - Formas de desinstabilização em uma barragens de concreto
 FONTE: O autor

2.2 INSTRUMENTOS DE MONITORAMENTO

Um sistema de instrumentação de monitoramento de barragem refere-se ao conjunto de dispositivos instalados nas estruturas e em suas fundações, objetivando monitorar seu desempenho através de medições de parâmetros, cujos resultados, devidamente analisados e interpretados, servirão para avaliar suas condições de segurança. Além de supervisionar as condições de segurança estrutural do empreendimento, durante toda sua vida útil, procura detectar antecipadamente qualquer eventual anomalia que possa comprometer o desempenho ou ameaçar a estabilidade da barragem, aferindo as hipóteses de projeto e a supervisão do desempenho das obras de reparo que venha, eventualmente, a ser implementadas. (ELETROBRÁS, 2003).

As grandezas a serem monitoradas em uma barragem são basicamente as subpressões na fundação, deslocamento na fundação, deslocamentos da barragem, tensões internas e vazões de infiltração. Medidas de variações de níveis d'água a montante e a jusante das estruturas, precipitação pluviométrica e de temperatura ambiente na área do projeto também devem ser efetuadas, pois serão de grande utilidade para auxiliar na análise e interpretação dos resultados da instrumentação (ICOLD, 2003).

É importante enfatizar que o fato de uma barragem estar instrumentada e analisada, não elimina a necessidade de inspeções visuais periódicas, as quais podem detectar anomalias impossíveis de serem detectadas com a instrumentação: fissuras ou trincas, surgimento de água, erosão ou degradação localizada de material. Assim, tanto a instrumentação de monitoramento como as inspeções visuais são igualmente importantes e devem ser utilizadas de forma conjunta na avaliação do desempenho e da segurança das barragens (CBGB, 1996).

A seguir será detalhado alguns dos instrumentos utilizados na metodologia deste trabalho.

Extensômetros: A medição dos recalques de uma barragem de concreto é uma das observações mais importantes na supervisão do comportamento da estrutura durante os períodos de construção, enchimento do reservatório e operação da barragem. A medição pode ser realizada por extensômetros múltiplos de hastes instalados em furos de sondagem. Com o uso de várias hastes, pode-se fazer a medição dos deslocamentos e deformações em vários trechos da fundação, dentre eles, contato concreto-rocha, juntas-falhas e outras descontinuidades sub-horizontais na fundação. Esta abordagem foi usada na barragem de Itaipu, onde diversos maciços de fundação foram instrumentados, em especial as descontinuidades geológicas (ITAIPU: USINA HIDRELÉTRICA, 2009).

Pêndulos Diretos: A medição de deslocamentos horizontais da crista são parâmetros de relevante importância, afetados por deflexões da estrutura de concreto, rotação da base da estrutura (devido à deformidade da fundação) ou influência térmicas ambientais. Estes deslocamentos são afetados por características do concreto ou por propriedades do maciço rochoso de fundação, resultando em importantes informações para a auscultação do comportamento da barragem e de sua fundação. Os deslocamentos horizontais da crista podem ser medidos por pêndulos diretos, normalmente instalados ao final do processo construtivo. As medições ocorrem nas fases de enchimento do reservatório e operação da barragem (SILVEIRA, 2003).

Piezômetros: A estabilidade da estrutura em termos de escorregamento, tombamento ou flutuação é diretamente afetada pelo nível das pressões piezométricas na interface concreto-rocha e nas descontinuidades sub-horizontais de baixa resistência ou alta permeabilidade existentes na fundação. A medição das subpressões na fundação das barragens de concreto é importante para a supervisão

de suas condições de segurança. A drenagem é um dos meios mais eficientes para assegurar coeficientes de segurança adequados (VILLWOCK, 2009).

Medidores de Vazão: A água infiltrada pelas fundações e pelo concreto pode ser medida por meio de medidores de vazão. Estas medições devem ser feitas durante o enchimento do reservatório e no período de operação, pois refletem imediatamente muitos dos problemas que ocorrem nas estruturas (ITAIPU: USINA HIDRELÉTRICA, 2009).

A partir de instrumentos instalados, espera-se que no período operacional da barragem seja possível verificar se a barragem está apresentando um desempenho geral satisfatório, conforme previsto em projeto; além de caracterizar o comportamento dos solos e maciço rochoso de fundação e das estruturas de barramento com o tempo, no sentido de verificar o prazo necessário para a estabilização dos deslocamentos, tensões internas, subpressões, vazões de drenagem, etc; e caracterizar o comportamento das estruturas da barragem em função da carga hidráulica, condições térmicas ambientais e fator tempo, após alguns anos de operação.

A aplicação de modelos matemáticos apropriados permite um melhor entendimento dos dados medidos pelos instrumentos, estabelecendo previsões sobre o comportamento futuro das estruturas, no sentido de facilitar a detecção de eventuais anomalias.

2.3 SEGURANÇA DA BARRAGEM DE ITAIPU

Itaipu, considerado um dos maiores projetos hidrelétricos do mundo é resultado dos esforços e empenho de dois países vizinhos, Brasil e Paraguai. Encontra-se localizado no rio Paraná, onde os dois países fazem fronteira, 14 km a montante da ponte internacional que liga a cidade de Foz do Iguaçu, no Brasil, à Ciudad del Este, no Paraguai (ITAIPU: USINA HIDRELÉTRICA, 2009).

A construção da Hidrelétrica de Itaipu foi de grande importância para o desenvolvimento do país. Uma obra muito avançada para época que envolveu em sua construção profissionais de alta capacidade (ITAIPU: USINA HIDRELÉTRICA, 2009).

A Barragem de Itaipu é uma estrutura que serve para represar a água e obter o desnível de 120 m (queda bruta nominal) que permite a operação das turbinas. Na FIGURA 2.2 observa-se uma vista superior do empreendimento, abrangendo grande parte das estruturas da barragem e do reservatório. Na parte superior da barragem principal, estão situadas as tomadas de água, estruturas com comportas que permitem que a água, passando por elas e pelos condutos forçados, alcance a caixa espiral, onde faz a turbina girar (ITAIPU, 2008).



FIGURA 2.2 – Vista da barragem de Itaipu com vertedouro em operação
FONTE: ITAIPU (2008)

A barragem da Itaipu possui 7.919 metros de extensão e altura máxima de 196 metros, consumiu 12,3 milhões de metros cúbicos de concreto, dimensões que transformaram a usina em referência nos estudos de concreto e na segurança de barragens. A barragem de Itaipu é composta por dois trechos de barragens de terra, um trecho de barragem de enrocamento e trechos de concreto, compondo as estruturas mais altas do conjunto (FIGURA 2.3).

Todas as barragens que compõem a Hidrelétrica de Itaipu apresentam um conjunto de instrumentos apropriados para cada tipo de estrutura, bem como para o maciço da fundação (PATIAS, 2010).

O principal objetivo da instalação de instrumentos no corpo das barragens de concreto, terra e enrocamento e suas respectivas fundações, é o de obter dados que possam caracterizar o comportamento real destas estruturas, e compará-los com o comportamento previsto com os modelos teóricos na fase de projeto.



FIGURA 2.3 – Configuração das estruturas da barragem de Itaipu
 FONTE: Site Itaipu Binacional¹

Os deslocamentos das estruturas e suas fundações são monitorados em Itaipu por meio de pêndulos do tipo direto e do tipo invertido, extensômetros de haste e medidores triortogonais. Além disso, nas barragens de terra são utilizados medidores de recalque na crista. Há ainda uma rede geodésica instalada a jusante da barragem de Itaipu, que permite medir os deslocamentos absolutos de toda a estrutura de barramento (ITAIPU, 2008).

Os pêndulos diretos permitem verificar o deslocamento da crista da barragem em relação a sua base, o qual é resultante tanto da rotação do bloco quanto da deformação do concreto estrutural. Este instrumento é constituído de um fio, que fixado na crista da barragem, ficando livre ao longo de toda a altura do bloco, estendendo-se até a base. O movimento do pêndulo medido na base da estrutura indica o deslocamento da crista. Os pêndulos invertidos permitem a observação dos movimentos da estrutura em relação a pontos interiores do maciço rochoso que possam ser considerados fixos (PATIAS, 2010).

Segundo Patias (2010), o deslocamento de camadas de rocha que constituem a fundação pode ser verificado por meio de extensômetros de haste, os quais possuem um ponto fixo localizado um ponto abaixo da camada que se deseja avaliar, os

1- Disponível em <<https://www.itaipu.gov.br/energia/barragem>>. Acesso em jan. 2016.

movimentos podem ser verticais (recalques ou elevações) e horizontais (para a direção de montante ou jusante).

Os instrumentos instalados nas estruturas de concreto são os tensômetros e deformímetros, os quais permitem avaliar as tensões no interior da massa de concreto; termômetros de superfície e de massa, que permitem avaliar as temperaturas externas e internas das estruturas e associá-las as deformações estruturais devidas a temperatura (ITAIPU: USINA HIDRELÉTRICA, 2009).

A instrumentação instalada nos maciços rochosos e terrosos que compõem a fundação das barragens de Itaipu tem por finalidade a obtenção de medidas de subpressão, infiltração de água e de deformações destes maciços (PATIAS *et al.*, 2015).

As subpressões são avaliadas por meio de medidas de piezômetros, os quais são instalados nas regiões do maciço rochoso que apresentam maior condutividade hidráulica (SILVEIRA, 2003).

A barragem de Itaipu também possui uma rede geodésica que permite avaliar os deslocamentos absolutos da estrutura, na direção vertical e horizontal. Esta rede é composta por pilares, que são considerados fixos, e por alvos geodésicos instalados em pontos específicos na área a jusante da crista das barragem de concreto e de enrocamento (PATIAS, 2010).

Os instrumentos foram instalados em locais que apresentassem um dos critérios descritos a seguir:

- Trechos com elevado número de blocos;
- Blocos de grandes dimensões, especialmente altura;
- Regiões da fundação com condições geológico-geotécnicas desfavoráveis.

Desta maneira, alguns blocos receberam instrumentação completa, abrangendo grande parte dos instrumentos descritos anteriormente, estes blocos são denominados blocos-chaves, outros receberam uma quantidade menor de instrumentos e, em outros foi instalado um sistema de instrumentação mínimo. A FIGURA 2.4 apresenta um conjunto completo de instrumentos de um bloco-chave.

Em toda a extensão da barragem de Itaipu, para acompanhar o desempenho das estruturas de concreto e fundação, são encontrados 2.400 instrumentos instalados, sendo que destes, 270 instrumentos considerados mais importantes receberam um sistema de aquisição automática de dados. Esses instrumentos possibilitam a aquisição das leituras com uma frequência parametrizável de 5 a 30 minutos, esses valores são

processados, armazenados e transmitidos para uma estação central, que é responsável pelo tratamento dos dados envolvendo análises, comparações e acionamento de alarmes (ITAIPU, 2008).




FIGURA 2.4 – Distribuição da instrumentação nas estruturas de concreto de Itaipu
FONTE: ITAIPU (2008)

2.4 DETECÇÃO DE FALHAS

O gerenciamento de riscos e de confiabilidade tem sido um importante fator de preocupação e desafio para a sociedade nas últimas décadas. Isto tem sido motivado tanto pela melhoria das exigências impostas pela sociedade com relação à segurança das pessoas envolvidas e do patrimônio e à preservação do meio ambiente como pela melhoria de eficiência, produtividade e competitividade em diversas áreas da indústria (SIMÕES FILHO, 2006).

Segundo a NBR 5462 (ABNT, 2004), confiabilidade é a capacidade de um item desempenhar a função requerida, sob condições de operações estabelecidas, por um período de tempo pré-determinado. As técnicas de análise de confiabilidade têm-se mostrado um poderoso instrumento para a tomada de decisões. Essas técnicas auxiliam no gerenciamento das atividades relativas ao ciclo de vida do projeto, possibilitando a implementação de políticas que minimizem os custos de operação, manutenção e inspeção de sistemas industriais e mantendo os níveis de segurança requeridos.

Entre as técnicas de análise de confiabilidade, a detecção segura de falhas em sistemas em que o comportamento depende do tempo (sistemas dinâmicos) tem concentrado muita atenção e recursos. Isso pode ser explicado pelos ganhos obtidos, pois a detecção antecipada de falhas permite um alto grau de confiabilidade ao funcionamento dos mesmos, evitando uma eventual parada de produção, perda de material e de qualidade na produção e até mesmo acidentes envolvendo seres humanos. Com isso, existe hoje uma crescente demanda no desenvolvimento de mecanismos que auxiliem na detecção de falhas de um sistema. Esses mecanismos são denotados por sistemas de supervisão FDI (*Fault Detection and Isolation*) (MOREIRA, 2011).

Falha é definida, na norma NBR 5462 (ABNT, 2004), como sendo a finalização da capacidade requerida de um item. No contexto de sistemas dinâmicos, pode-se ainda subdividir o conceito de falhas em dois grupos (FIGURA 2.5) (D'ANGELO *et al.*, 2011a):

- (i) Falhas Abruptas: são as que acontecem em um curto espaço de tempo, e que resultam em grandes desvios nas condições normais de operação do processo;
- (ii) Falhas Incipientes: são as que afetam gradualmente o funcionamento normal do processo, e por isso podem levar um tempo maior para serem detectadas.

Existem várias estratégias para tratar os problemas FDI. Uma importante linha de tratamento para o problema de FDI, é baseado em modelos quantitativos focados em abordagens analíticas, tais como observadores e filtros, que geram sinais para detectar a inconsistência entre a operação normal e anormal do sistema (JIANG; ZHOU, 2005), (PUIG *et al.*, 2006) e (DAI *et al.*, 2009). Outra abordagem no contexto de modelos quantitativos é dada pelas relações de paridade (PLOIX; ADROT, 2006), onde são verificadas a paridade (consistência) dos modelos da planta, as saídas dos sensores (medições) e as entradas conhecidas da planta. Nos casos em que os modelos matemáticos que descrevem o sistema são não-lineares, a utilização de modelos *fuzzy* tem se mostrado um método interessante (CALADO *et al.*, 2001).




FIGURA 2.5 - Tipos de Falhas
FONTE: SOUZA (2013)

No caso de problemas que não possuem modelos matemáticos explícitos, devido a difícil obtenção, o uso de técnicas como redes neurais, lógica *fuzzy*, algoritmos genéricos podem gerar soluções eficientes (LO; FUNG; WONG, 2009), (RIGATOS; ZHANG, 2009), (BARTYS *et al.*, 2006) e (WITCZAK *et al.*, 2006).

Também existem na literatura trabalhos que exploram o uso de estatística *Bayesiana* para a detecção de falhas (TANG, 2000) e (MAST *et al.*, 1999). Destaca-se nesta linha, o uso de redes *Bayesianas*, que são grafos orientados que representam a dependência probabilística entre as variáveis como uma forma de modelar a incerteza associada com o modelo.

Uma técnica que é utilizada para a detecção de falhas neste estudo é dada nos trabalhos apresentados em (D'ANGELO *et al.*, 2011a), (D'ANGELO, 2010) e (MOREIRA, 2011). A metodologia apresentada nesses trabalhos se baseia na teoria dos conjuntos *fuzzy* associada com a estatística *Bayesiana*, e tem como principal contribuição uma abordagem que permite a detecção de falhas incipientes (as outras técnicas em geral lidam com falhas abruptas, mais simples de serem detectadas) sem a necessidade de modelos determinísticos ou probabilísticos.

Para um bom entendimento da teoria é necessária uma revisão de tópicos de rede neural de Kohonen, conjuntos *fuzzy* e simulação de Monte Carlo via cadeia de Markov.

2.5 MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

A automação de processos e o desenvolvimento de sistemas em diversas áreas como finanças, ciências econômicas, ciências sociais, meteorologia e energia entre outros, tem fornecido, além dos produtos decorrentes de cada uma dessas áreas, muita informação associadas a elas. Diferentes informações são geradas ao longo das inúmeras etapas associadas aos processos, bem como das observações de fenômenos naturais e experimentos relacionados. Assim, muitos dos dados que hoje são coletados e armazenados, estão associados, de alguma forma, à dimensão tempo (BATISTA, 2010).

Surgem então, dessa dimensão adicional, associada aos dados do domínio, inúmeras possibilidades de análises, que vão além das funções básicas como contabilização, cálculo da média e obtenção dos valores extremos que ocorrem. Ao se considerar a restrição temporal, os dados passam a formar um conjunto ordenado chamado série temporal, permitindo que sejam estimadas tendências e observações

padrões, possibilitando a descoberta de informações adicionais sobre o domínio do problema.

Definição 1: Uma Série Temporal é um conjunto ordenado $T = \{x_1, x_2, \dots, x_n\}$ de n variáveis observadas sequencialmente no tempo.

A abordagem utilizada para tratar dos problemas matemáticos e estatísticos levantados por correlações entre o tempo e seu relativo valor é conhecida por análise de séries temporais.

Muitas vezes a análise de série temporal é feita através de comparações da série com ela mesma ou com suas partes. Uma abordagem frequentemente usada consiste em estipular um tamanho w e obter todas as possíveis subsequências da série original com esse tamanho.

Definição 2: Dada uma série temporal T de tamanho n , uma subsequência S de T é uma amostra de posições contíguas de tamanho $w < n$ em T , isto é, $S = x_p, \dots, x_{p+w-1}$, para $1 \leq p \leq n - w + 1$.

A técnica de janela deslizante consiste em percorrer toda a série T através de subsequências S (FIGURA 2.6).




FIGURA 2.6 - Técnica de janela deslizante
FONTE: BATISTA (2010)

Uma das técnicas bastante utilizada na análise de séries temporais é a de clusterização da série, que consiste em agrupar as sequências semelhantes em grupos distintos, usando-se a distância Euclidiana como critério de similaridade. Entre os algoritmos de clusterização, talvez o mais popular seja o das k -médias. Como parâmetro para esse algoritmo é preciso definir de antemão o valor de k , que é a quantidade de grupos (de agora em diante chamados de *clusters*) a serem gerados.

Porém, o número de *clusters* k é um parâmetro crítico, que refletirá o número de grupos distintos aos quais se quer agrupar as observações. Em se tratando da descoberta de padrões desconhecidos em séries temporais, não é tarefa fácil afirmar *a priori* sobre a existência de um padrão, sendo ainda mais difícil especificar a quantidade de padrões distintos k que espera-se encontrar.

Uma solução parcial para o problema de fixar a quantidade de padrões é apresentada pelos Mapas Auto-Organizáveis (SOM – *Self-Organizing Maps*) de Kohonen, com a introdução de redundância. Um SOM é um algoritmo de clusterização baseado em rede neural com capacidade de auto-organização e de aprendizado não supervisionado (BATISTA, 2010).

As arquiteturas auto-organizáveis, como propostas por Kohonen (1982), geram mapeamentos de um espaço de dimensão elevada em estruturas cuja dimensão topológica é inferior à original. Esses mapeamentos são capazes de preservar as relações de vizinhança dos dados de entrada. Os mapas auto-organizáveis de Kohonen fazem parte de um grupo de redes neurais baseadas em modelos de competição, ou simplesmente chamadas de redes competitivas. Essas redes combinam método de competição com um método de aprendizagem para fazer os ajustes de seus pesos. Outra característica importante, é o treinamento não-supervisionado, onde a rede busca encontrar similaridades baseando-se apenas nos padrões de entrada. O principal objetivo dos SOM é agrupar os dados de entrada que são semelhantes entre si formando *clusters* (SILVA, 1998).

Como em uma rede neural, a estrutura de um SOM é construída tendo o neurônio artificial como a unidade mais básica de processamento. Cada um dos nós (neurônios) da rede possui uma posição topológica específica (uma coordenada x e y , por exemplo) e um vetor de pesos com a mesma dimensão que os vetores de entrada (FIGURA 2.7).

Os nós do SOM são organizados em estruturas que podem corresponder a mapas unidimensionais ou multidimensionais, variando de acordo com a aplicação. Na FIGURA 2.8 pode-se observar um SOM com 16 nós, organizados em um mapa bidimensional (4x4). As linhas que conectam os neurônios servem apenas para representar a vizinhança de cada um, não correspondendo a qualquer ligação estrutural entre os mesmos. Adicionalmente, cada um dos nós da rede é ligado aos vetores de entrada (vetor de treinamento).

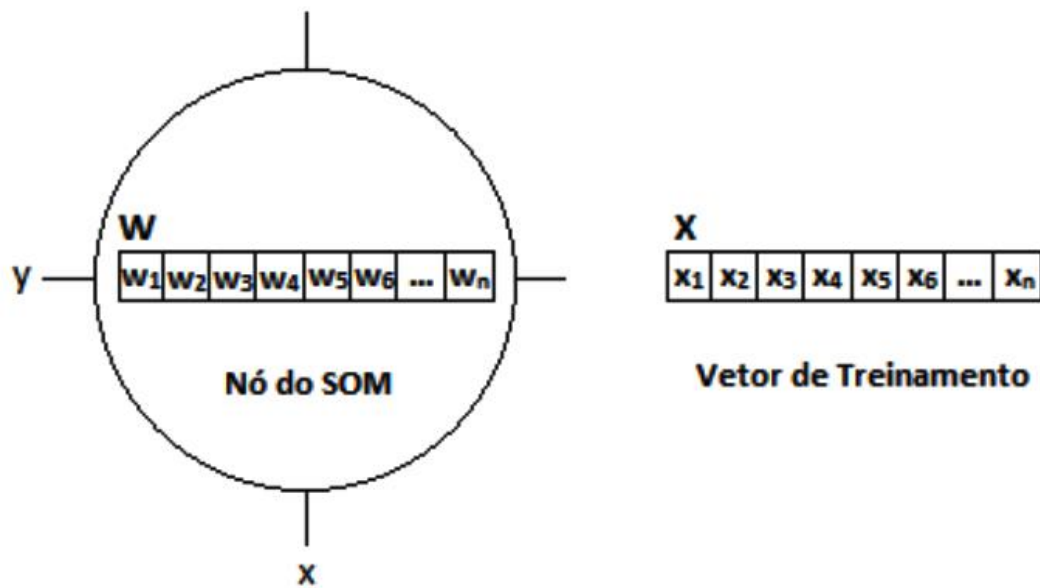


FIGURA 2.7 - Estrutura do nó básico do SOM
 FONTE: SILVA (1998)

Como visto anteriormente, o aprendizado no SOM é baseado no aprendizado competitivo onde os nós de saída da rede competem entre si para serem ativados. A formação do mapa ocorre em duas etapas: a estruturação inicial, que organiza os padrões de entrada no mapa, e a convergência final, responsável pelo refinamento.

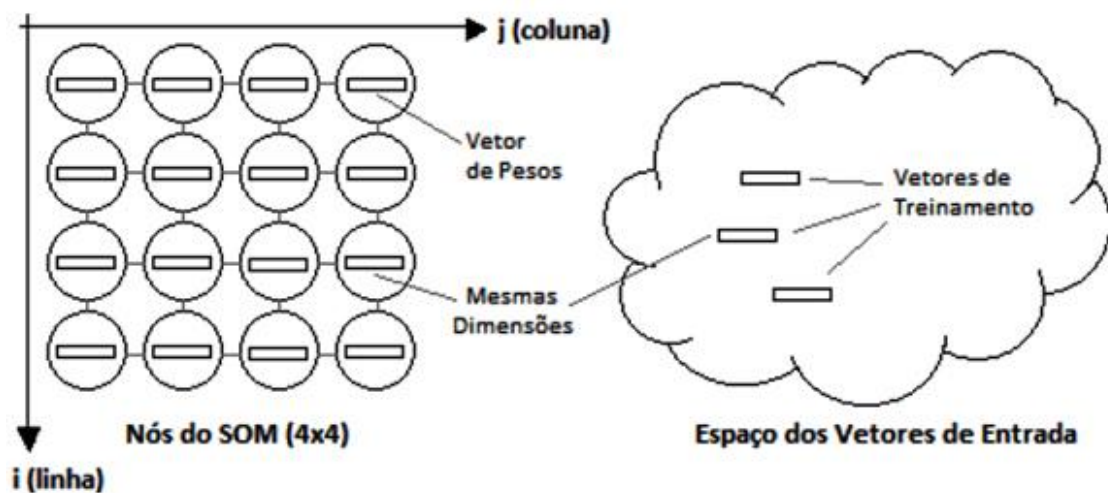


FIGURA 2.8 - Exemplo de uma rede SOM bidimensional
 FONTE: SILVA (1998)

A segunda etapa leva mais tempo que a primeira, e é caracterizada pelos valores pequenos da taxa de aprendizado. Como muitas iterações através do conjunto

de treinamento podem ser necessárias, costuma-se também estipular um máximo de iterações como condição de término do algoritmo.

Durante a fase de aprendizado, calcula-se a distância de cada um dos nós para o padrão apresentado e identifica-se o vencedor. Isso permite especificar qual região do mapa será responsável por aprender o novo padrão.

O algoritmo de treinamento do SOM é apresentado abaixo (SILVA, 1998):

1. Inicialização e definições de parâmetros:
 - Inicialize os pesos w_{ij} .
 - Defina o Raio de vizinhança R .
 - Defina o parâmetro de aprendizagem α .
2. Enquanto a condição de parada é falsa, faça:
 - 2.1. Para cada j calcule:
 - 2.1.1. $D(j) = \sqrt{\sum_i (w_{ij} - x_i)^2}$.
 - 2.1.2. Encontrar o índice J tal que $D(J)$ é mínimo (vencedor).
 - 2.1.3. $\forall j$ pertencente a vizinhança definida por R de J , e $\forall i$ faça:

$$w_{ij}(\text{novo}) = w_{ij}(\text{antigo}) + \alpha [x_i - w_{ij}(\text{antigo})].$$
 - 2.2. Atualize a taxa de aprendizagem α .
 - 2.3. Reduza o raio de vizinhança R .

Em seguida, será melhor apresentado algumas etapas do algoritmo:

Inicialização dos pesos: Antes do treinamento de rede, os pesos (w_{ij}) dos nós do SOM devem ser inicializados. A inicialização dos pesos pode se dar através da atribuição de valores aleatórios ou, caso alguma informação referente à distribuição dos agrupamentos estiver disponível, receberem valores que reflitam um conhecimento prévio sobre a estrutura do mapa.

Escolha do vencedor: O nó vencedor é o nó da rede que possui pesos que mais se aproximam do vetor de entrada. Tal nó pode ser encontrado percorrendo-se todos os nós da rede e, para cada um, calculando-se a distância euclidiana entre os pesos do mesmo em relação ao vetor de entrada. O nó com a menor distância euclidiana é o vencedor.

Determinação da Vizinhança Local do Vencedor: O nó vencedor é calculado a cada iteração, e em seguida calcula-se quais nós pertencem à sua vizinhança local.

Isso pode ser feito simplesmente tomando-se os vizinhos imediatamente adjacentes ou de forma mais elaborada levando-se em consideração um raio R , que decresce ao longo das iterações, respeitando a topologia da rede. Para fazer o raio da vizinhança decrescer ao longo do tempo, pode-se usar funções decrescentes que dependem do número de iterações. Tais funções resultam em valores para R que variam entre o raio inicial, resultante da primeira iteração, e 1, resultante do valor limite de iterações.

Ajuste dos Pesos: Todos os nós dentro da vizinhança do vencedor têm seus pesos ajustados de acordo com a equação

$$w_{ij}(\text{novo}) = w_{ij}(\text{antigo}) + \alpha[x_i - w_{ij}(\text{antigo})], \quad (1)$$

onde α representa a taxa de aprendizado que será atualizada a cada iteração.

Após o algoritmo aplicado, tem-se que um SOM atua como um processo de clusterização, agrupando padrões temporais similares dispersos na série. A rede treinada, após o processo de aprendizado (clusterização) agrupa um conjunto de padrões p_1, p_2, \dots, p_k , onde k é o número de nós na camada de saída, porém apenas nesse processo, pode ocorrer redundâncias.

Para contornar esse problema, existe um processo de remoção de redundância, que é um refinamento para o algoritmo de aprendizagem do SOM, e tem como finalidade reduzir a quantidade de padrões encontrados, mantendo apenas os mais significativos. Isso é feito em duas etapas:

A primeira delas consiste em percorrer novamente o conjunto das entradas e identificar, para cada uma, qual dos padrões encontrados que a representa melhor (maior similaridade); um contador das ocorrências é mantido para cada padrão e, ao final do processo, removem-se os padrões que não tiveram ocorrências.

A segunda etapa, responsável por agrupar padrões similares e redundantes, consiste em calcular a distância entre todos os padrões encontrados e agrupar os mais semelhantes em um novo padrão. Isso é feito respeitando-se uma constante de diferença máxima tolerada, que é a distância máxima permitida entre dois padrões para que o agrupamento entre eles ocorra. O novo padrão é então calculado respeitando-se o peso que cada um dos padrões tinha sobre o conjunto de subsequências (quantidade de ocorrências). O processo é repetido enquanto existirem pares de padrões com distância menor que a máxima tolerada.

2.6 CONJUNTOS *FUZZY*

A noção de conjunto *fuzzy*, dada por Zadeh (1965), estende aquela de conjunto clássico no sentido de que a relação de pertinência de um elemento a um conjunto deixa de ser uma relação dicotômica, isto é, para um subconjunto A de um conjunto universo X e um elemento $x \in X$, tem-se apenas as possibilidades de $x \in A$ ou $x \notin A$ (ZIMMERMANN, 2010). Por exemplo, sabe-se que o número 3 pertence ao conjunto dos números ímpares e que o número 4 não pertence ao mesmo conjunto. No entanto, pode-se discordar quanto ao fato de o número 10 pertencer ou não ao conjunto dos números naturais “pequenos”. Neste caso a resposta não é objetiva. Pertencer ou não pode depender do tipo de problema em mãos. Este exemplo é apenas uma das inúmeras situações em que o significado de pertinência não está definido e, neste caso, não se sabe dizer se o elemento pertence ou não a um dado conjunto (BANDO, 2002).

A ideia de Zadeh foi flexibilizar a pertinência de elementos aos conjuntos criando a noção de grau de pertinência. Um elemento pode pertencer parcialmente a um dado conjunto. Voltando ao caso do conjunto dos números naturais “pequenos”, pode-se dizer que o número 1 tem um grau de pertinência maior que o grau de pertinência do número 10 em relação a este conjunto. Para modelar matematicamente este “conjunto”, foi proposto o conceito de conjunto *fuzzy*.

A formalização matemática de um conjunto *fuzzy* é baseada no fato de que todo subconjunto clássico A de um conjunto universo $X \neq \emptyset$ pode ser caracterizado por uma função denominada função característica do conjunto A , definida por

$$\chi_A(x) = \begin{cases} 1 & \text{se } x \in A; \\ 0 & \text{se } x \notin A. \end{cases} \quad (2)$$

Pode-se notar que o objetivo da função característica de um subconjunto $A \subset X$ é indicar se um elemento $x \in X$ pertence ou não a A , dependendo de sua imagem em $\{0,1\}$. Assim, a função característica descreve completamente o conjunto A , já que indica quais elementos do conjunto X são elementos de A (ORTEGA, 2001).

Baseando-se em uma “generalização” da função característica de um conjunto, é definido um subconjunto *fuzzy*.

Definição 3: Um subconjunto *fuzzy* A do conjunto universo X é caracterizado por uma função $\mu_A: X \rightarrow [0, 1]$, chamada função pertinência do conjunto *fuzzy* A .

O valor $\mu_A(x) \in [0, 1]$ indica o grau com que o elemento x de X pertence ao conjunto *fuzzy* A , com $\mu_A(x) = 0$ e $\mu_A(x) = 1$ indicando, respectivamente, a não pertinência e a pertinência completa de x ao conjunto *fuzzy* A . Observa-se que a definição de conjunto *fuzzy* foi obtida simplesmente ampliando-se o contradomínio da função característica, isto é, do conjunto $\{0, 1\}$, para o intervalo $[0, 1]$. Assim todo conjunto clássico é um caso particular de conjunto *fuzzy*, onde a função pertinência que o caracteriza é sua função característica.

Observações:

1. Com o intuito de simplificar o texto, subconjunto *fuzzy* é referido apenas por conjunto *fuzzy*;
2. No caso de um conjunto clássico A , é dito apenas conjunto A , sem a palavra “clássico”. Porém se A for um conjunto *fuzzy*, é utilizado a palavra *fuzzy* para diferenciá-lo do conjunto clássico;
3. Fixado o conjunto X , foi visto que a função μ_A caracteriza completamente o conjunto *fuzzy* A . Por este motivo, é referido ao conjunto *fuzzy* A , apenas a sua função pertinência μ_A .

No exemplo do conjunto P dos números naturais “pequenos”, tinha-se pela teoria clássica de conjuntos algumas dúvidas: o número 1 pertence a esse conjunto? E o número 99? Através da teoria *fuzzy*, pode-se dizer que ambos pertencem a P , porém com diferentes graus de pertinência, de acordo com a propriedade que o caracteriza. Uma forma para a função pertinência P pode ser dada por:

$$\mu_P(n) = \frac{1}{n + 1}. \quad (3)$$

Neste caso o número 1 pertence a P com grau de pertinência $\mu_P(1) = 0,5$, enquanto 99 pertence a P com grau de pertinência $\mu_P(99) = 0,01$.

A escolha de qual função deve ser adotada para representar o conjunto *fuzzy* em questão depende dos fatores que estão relacionados com o contexto do problema a ser estudado.

2.6.1 Operações entre Conjuntos *Fuzzy*

Sendo A e B subconjuntos de X representados pelas funções características χ_A e χ_B , respectivamente. Tem-se que os conjuntos

$$A \cup B = \{x; x \in A \text{ ou } x \in B\},$$

$$A \cap B = \{x; x \in A \text{ e } x \in B\},$$

$$A' = \{x; x \notin A\},$$

possuem respectivamente as funções características,

$$\chi_{A \cup B}(x) = \max\{\chi_A, \chi_B\},$$

$$\chi_{A \cap B}(x) = \min\{\chi_A, \chi_B\},$$

$$\chi_{A'}(x) = 1 - \chi_A.$$

Considerando novamente em conjuntos *fuzzy* como sendo uma extensão de funções características, pode-se definir união, intersecção e complementar de conjuntos *fuzzy* (NGUYEN; WALKER, 1997).

Definição 4: Sejam A e B conjuntos *fuzzy*. As funções pertinências que representam os conjuntos *fuzzy* união, intersecção e complementar de conjuntos *fuzzy* são dadas por

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} = \mu_A(x) \vee \mu_B(x),$$

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} = \mu_A(x) \wedge \mu_B(x),$$

$$\mu_{A'}(x) = 1 - \mu_A(x),$$

respectivamente.

Alguns conjuntos *fuzzy* com propriedades especiais são muito utilizados no decorrer do texto, assim são denotados com nomes especiais, por exemplo:

Definição 5: Um conjunto *fuzzy* A é dito normal se $\mu_A(x) = 1$ para algum $x \in X$.

2.6.2 Números *Fuzzy*

Assim como no caso clássico, na teoria de conjuntos *fuzzy* também tem-se o objetivo de fazer operações de adição e subtração, por exemplo. A diferença está no fato de que agora se pretende calcular quantidades imprecisas. Por exemplo, é comum afirmar que o dobro de uma quantidade “em torno de 5” resulta em outra “em torno de 10”. Para isto, são criados objetos que generalizam a ideia de número. Tais objetos são chamados de números *fuzzy* (BANDO, 2002).

O conceito de número *fuzzy* vem do fato de muitos fenômenos não podem ser caracterizados por um valor preciso (número real). De um modo geral pode-se dizer que, em um problema concreto, muitos números que lá aparecem são idealizações de informações imprecisas envolvendo valores numéricos. Por exemplo, quando é medido o comprimento de algum objeto, o que se obtém é um valor numérico carregado de imprecisões. Tais imprecisões podem ter sido causadas pelos instrumentos de medidas, pelo indivíduo que está medido, pelo objeto que está sendo medido e outros fatores. Por fim é aceito um valor exato (um número real) l para indicar o comprimento. No entanto, seria mais prudente dizer que o comprimento é “em torno de l ”. Neste caso, matematicamente, indica-se a expressão “em torno de l ” por um conjunto *fuzzy* A cujo domínio é o conjunto dos números reais. Também é razoável esperar que $\mu_A(l) = 1$ (BARROS; BASSANEZI, 2010).

A fim de definir formalmente um número *fuzzy*, é de fundamental importância a definição do conceito de nível de um conjunto *fuzzy*, pois, possibilita o entendimento de um conjunto *fuzzy* através de uma classe especial de conjuntos clássicos.

Definição 6: Sejam A um conjunto *fuzzy* e $\alpha \in [0, 1]$. Define-se α -nível de A o conjunto

$$[A]^\alpha = \{x \in X; \mu_A(x) \geq \alpha\} \quad (\alpha > 0) \quad (4)$$

e

$$[A]^0 = \overline{\{x \in X; \mu_A(x) > 0\}} \quad (\text{denotado por } \textit{suporte de } A). \quad (5)$$

Desse modo, um número *fuzzy* pode ser definido por:

Definição 7: Um conjunto *fuzzy* N é chamado *número fuzzy* quando o conjunto universo, onde N está definido, é o conjunto dos números reais e satisfaz às condições:

1. $[N]^\alpha \neq \emptyset, \forall \alpha \in [0, 1]$;
2. $[N]^\alpha$ é um intervalo fechado, $\forall \alpha \in [0, 1]$;
3. O suporte de N , $\text{supp}(N) = [N]^0$, é limitado.

Pela definição acima, todo número real r é um caso particular de número *fuzzy* cuja a função de pertinência é sua função característica.

$$\chi_{\{r\}}(x) = \begin{cases} 1 & \text{se } x = r \\ 0 & \text{se } x \neq r \end{cases} \quad (6)$$

A partir de agora, utiliza-se \tilde{r} para denotar $\chi_{\{r\}}(x)$.

A seguir são exemplificados os tipos mais comuns de números *fuzzy*.

Exemplo 1: Um número *fuzzy* A é dito triangular se sua função de pertinência é da forma

$$\mu_A(x) = \begin{cases} 0 & \text{se } x < a \\ \frac{x-a}{b-a} & \text{se } a \leq x < b \\ \frac{b-x}{b-c} & \text{se } b \leq x < c \\ 0 & \text{se } x > c \end{cases} \quad (7)$$

para $a < b < c$.

O gráfico de um número *fuzzy* triangular tem a forma de um triângulo (FIGURA 2.9), tendo como base o intervalo $[a, b]$ e, como único vértice fora dessa base, o ponto $(b, 1)$. Tem-se que neste caso que $\mu_A(b) = 1$, assim um número *fuzzy* triangular é um modelo matemático razoável para a expressão linguística “perto de b ”. O mesmo não se pode dizer da expressão “em torno de b ”, onde se espera uma simetria.




FIGURA 2.9 - Número *fuzzy* triangular
FONTE: O autor

Exemplo 2: Um número *fuzzy* A é dito trapezoidal se sua função de pertinência é da forma

$$\mu_A(x) = \begin{cases} 0 & \text{se } x < a \\ \frac{x-a}{b-a} & \text{se } a \leq x < b \\ 1 & \text{se } b \leq x < c \\ \frac{x-d}{c-d} & \text{se } c \leq x < d \\ 0 & \text{se } x > d \end{cases} \quad (8)$$

para $a < b < c < d$.

O gráfico de um número *fuzzy* trapezoidal tem a forma de um trapézio cuja a base maior é dada pelo intervalo $[a, d]$ (FIGURA 2.10).




FIGURA 2.10 - Número *fuzzy* trapezoidal
FONTE: O autor

Exemplo 3: Um número *fuzzy* A é dito forma-S se sua função de pertinência é da forma

$$\mu_A(x) = \begin{cases} 0 & \text{se } x < a \\ \frac{x-a}{b-a} & \text{se } a \leq x < b. \\ 1 & \text{se } x \geq b \end{cases} \quad (9)$$

para $a < b$.

Este número *fuzzy* recebe este nome devido ao seu gráfico ter a forma parecida com a letra “S” (FIGURA 2.11).




FIGURA 2.11 - Número *fuzzy* forma-S
FONTE: O autor

Exemplo 4: Um número *fuzzy* A é dito forma-Z se sua função de pertinência é da forma

$$\mu_A(x) = \begin{cases} 1 & \text{se } x < a \\ \frac{x-b}{a-b} & \text{se } a \leq x < b \\ 0 & \text{se } x \geq b \end{cases} \quad (10)$$

para $a < b$.

Este número *fuzzy* recebe este nome, também devido ao seu gráfico ter a forma parecida de uma letra, neste caso, a letra “Z” (FIGURA 2.12).




FIGURA 2.12 - Número *fuzzy* forma-Z
FONTE: O autor

Observe-se que um número *fuzzy* trapezoidal A do exemplo 2 é definido pelos números a, b, c e d , desse modo, é comum denotar um número *fuzzy* trapezoidal por uma quadra ordenada, isto é, $\tilde{A} = (a; b; c; d)$.

Seguindo o mesmo raciocínio, tem-se que $\tilde{A} = (a; b; b; c)$ representa o número *fuzzy* triangular do exemplo 1. A fim de utilizar a mesma notação, denotam-se por $\tilde{A} = (a; b; \infty; \infty)$ o número *fuzzy* de forma-S do exemplo 3 e $\tilde{A} = (-\infty; -\infty; a; b)$ o número *fuzzy* de forma-Z do exemplo 4.

2.6.3 Relações *Fuzzy*

O conceito de uma relação matemática é formalizado utilizando-se do produto cartesiano clássico entre conjuntos. Da teoria de conjuntos clássicos, dados os conjuntos A e B , define-se produto cartesiano entre estes como sendo o conjunto

$$A \times B = \{(a, b); a \in A \text{ e } b \in B\}. \quad (11)$$

Assim, a função característica que representa o produto cartesiano entre os conjuntos A e B é dada por

$$\chi_{A \times B}(a, b) = \begin{cases} 1 & \text{se } a \in A \text{ e } b \in B \\ 0 & \text{se } a \notin A \text{ ou } b \notin B \end{cases}, \quad (12)$$

ou simplesmente

$$\chi_{A \times B}(a, b) = \chi_A(a) \wedge \chi_B(b). \quad (13)$$

Tratando conjuntos *fuzzy* como sendo uma extensão de conjuntos clássicos a partir da ampliação do contradomínio da função característica, pode-se definir produto cartesiano entre os conjuntos *fuzzy* A e B como sendo o conjunto representado pela função pertinência

$$\mu_{A \times B}(a, b) = \mu_A(a) \wedge \mu_B(b). \quad (14)$$

Logo a definição que generaliza o produto cartesiano *fuzzy* é dada da seguinte maneira (DUBOIS; PRADE, 1980).

Definição 8: O produto cartesiano *fuzzy* dos subconjuntos *fuzzy* A_1, A_2, \dots, A_n de X_1, X_2, \dots, X_n , respectivamente, é a relação *fuzzy* $A_1 \times A_2 \times \dots \times A_n$ representada pela função pertinência

$$\mu_{A_1 \times A_2 \times \dots \times A_n}(a_1, a_2, \dots, a_n) = \mu_{A_1}(a_1) \wedge \mu_{A_2}(a_2) \wedge \dots \wedge \mu_{A_n}(a_n). \quad (15)$$

para todo $(a_1, a_2, \dots, a_n) \in X_1, X_2, \dots, X_n$.

A noção e utilização de produto cartesiano *fuzzy* ficará mais clara na próxima seção, onde será introduzido o conceito de sistemas *fuzzy*, que são sistemas compostos de regras da forma “Se...Então”. Vai ser mostrado que essas regras são produtos cartesianos de conjuntos *fuzzy*. Sendo assim, um produto cartesiano *fuzzy* será uma possível forma de modelar declarações do tipo “Se...Então”.

2.7 LÓGICA FUZZY

Na literatura, o termo “lógica *fuzzy*” é utilizado de duas formas: a primeira refere-se à extensão da lógica clássica. A segunda é para representar e manipular informações inexatas com o propósito de tomar decisões, lançando mão da teoria dos conjuntos *fuzzy*, de suas funções de pertinência e suas álgebras em geral (BARROS; BASSANEZI, 2010), que é o objetivo deste capítulo.

Os primeiros passos no estudo de modelagem matemática de termos linguísticos é a realização de estudo dos conectivos lógicos: “e” e “ou”.

2.7.1 Conectivos Básicos da Lógica *Fuzzy*

Primeiramente considere-se o conectivo “e”. Sob o ponto de vista da teoria clássica “um número natural n é par e maior que cinco” se ele pertencer ao conjunto dos números naturais pares e ao conjunto dos números maiores que cinco, ou melhor, se n pertencer a intersecção destes conjuntos. Sendo assim, uma maneira de modelar o conectivo “e” na teoria clássica é utilizando intersecção de conjuntos. Anteriormente, viu-se que a extensão de intersecção de conjuntos para intersecção de conjuntos *fuzzy* é dada por meio da aplicação $x \wedge y = \min\{x, y\}$.

Analogamente, uma modelagem para o termo “ou” na teoria clássica é através da união de conjuntos, pois um elemento pertence a um conjunto A ou ao conjunto B se ele pertencer a união dos conjuntos A e B . Também, foi descrito nas seções anteriores que a extensão de união de conjuntos para união de conjuntos *fuzzy* é por meio da aplicação $x \vee y = \max\{x, y\}$.

Baseado nos estudos de Espaços Métricos Estatísticos, a fim de destacar quais são as principais propriedades que certas aplicações necessitam para modelar os conectivos “e” e “ou”, surge uma generalização dessas aplicações definidas por Barros e Bassanezi (2010):

Definição 9 (t-norma): O operador $\Delta: [0,1] \times [0,1] \rightarrow [0,1]$, $\Delta(x,y) = x\Delta y$, é uma t-norma, se satisfaz as seguintes condições:

- (1) Elemento neutro: $\Delta(1,x) = x$;
- (2) Comutativa: $\Delta(x,y) = \Delta(y,x)$;
- (3) Associativa: $x\Delta(y\Delta z) = (x\Delta y)\Delta z$;
- (4) Monotonicidade: se $x \leq u$ e $y \leq v$, então $\Delta(x,y) \leq \Delta(u,v)$.

A operação t-norma estende o operador \wedge que modela o conectivo “e”.

Exemplo 5: Exemplos de t-normas

- (a) $\Delta_1(x,y) = x \wedge y$ (usual);
- (b) $\Delta_2(x,y) = 0 \vee (x + y - 1)$;
- (c) $\Delta_3(x,y) = xy$;
- (d) $\Delta_4(x,y) = \frac{xy}{x+y-xy}$.

Definição 10 (t-conorma): O operador $\nabla: [0,1] \times [0,1] \rightarrow [0,1]$, $\nabla(x,y) = x\nabla y$, é uma t-conorma, se satisfaz as seguintes condições:

- (1) Elemento neutro: $\nabla(0,x) = x$;
- (2) Comutativa: $\nabla(x,y) = \nabla(y,x)$;
- (3) Associativa: $x\nabla(y\nabla z) = (x\nabla y)\nabla z$;
- (4) Monotonicidade: se $x \leq u$ e $y \leq v$, então $\nabla(x,y) \leq \nabla(u,v)$.

A operação t-conorma estende o operador \vee que modela o conectivo “ou”.

Exemplo 6: Exemplos de t-conormas

- (a) $\nabla_1(x, y) = x \vee y$ (usual);
- (b) $\Delta_2(x, y) = 1 \wedge (x + y)$;
- (c) $\Delta_3(x, y) = x + y - xy$;
- (d) $\Delta_4(x, y) = \frac{x+y}{1+xy}$.

2.7.2 Sistemas Fuzzy

Considera-se um sistema onde uma entrada $x = (x_1, x_2, \dots, x_n) \in X^n$ que produz uma saída $y \in Y$. Suponha-se que a relação $y = f(x)$ não seja conhecida, mas o que associa uma entrada à sua saída pode ser representada por uma coleção de regras linguísticas da forma

$$\begin{aligned} R_1: & \text{"Se } x_1 \text{ é } A_{11} \text{ e } \dots \text{ e } x_n \text{ é } A_{n1} \text{ então } y \text{ é } B_1"; \\ R_2: & \text{"Se } x_1 \text{ é } A_{12} \text{ e } \dots \text{ e } x_n \text{ é } A_{n2} \text{ então } y \text{ é } B_2"; \\ & \vdots \\ R_r: & \text{"Se } x_1 \text{ é } A_{1r} \text{ e } \dots \text{ e } x_n \text{ é } A_{nr} \text{ então } y \text{ é } B_r, \end{aligned}$$

onde os A 's e B 's são termos linguísticos representados por conjuntos *fuzzy* de X e Y . Portanto, estas regras formam o que chamam-se de *base de regras fuzzy*, e cada regra é dita uma regra *fuzzy* (ORTEGA, 2001).

Analisa-se separadamente a regra *fuzzy*

$$R_i: \text{"Se } x_1 \text{ é } A_{1i} \text{ e } \dots \text{ e } x_n \text{ é } A_{ni} \text{ então } y \text{ é } B_i",$$

onde o termo " x_k é A_{ki} " significa o quanto x_k pertence ao conjunto *fuzzy* A_{ki} , que é dado por $\mu_{A_{ki}}(x_k)$. Em seguida, o termo "e" pode ser modelado com uma t-norma, e assim a expressão " x_1 é A_{1i} e \dots e x_n é A_{ni} " é traduzida matematicamente para $\mu_{A_{1i}}(x_1) \Delta \dots \Delta \mu_{A_{ni}}(x_n)$. Assim, pela definição 9, tem-se que a frase

$$"x_1 \text{ é } A_{1i} \text{ e } \dots \text{ e } x_n \text{ é } A_{ni}"$$

é modelada pelo produto cartesiano dos conjuntos *fuzzy* A_{1i}, \dots, A_{ni} , que será denotado por $A_i = A_{1i} \times \dots \times A_{ni}$, aplicado no elemento $x = (x_1, \dots, x_n)$. Então a regra R_i pode ser escrita da seguinte forma

$$R_i: "Se x é A_i, então y é B_i",$$

que pelas seções anteriores, significa o produto cartesiano *fuzzy* $(A_i \times B_i)$. Portanto, como a entrada $x = (x_1, \dots, x_n) \in X^n$ é dada, cada regra *fuzzy* da base de regras pode ser escrita como um conjunto *fuzzy* com função pertinência

$$\mu_{R_i}(y) = \mu_{A_{1i}}(x_1) \Delta \dots \Delta \mu_{A_{ni}}(x_n) \Delta \mu_{B_i}(y) \quad (16)$$

aplicada em $y \in Y$.

Analizando agora o sistema *fuzzy* como um todo. Dado $x = (x_1, x_2, \dots, x_n) \in X^n$ tem-se que x satisfaz a regra R_1 ou a regra R_2 ou a regra R_3 , assim por diante, usando uma t-conorma para modelar o termo “ou”, tem-se que um sistema *fuzzy* com k regras é o conjunto *fuzzy* S representado pela função pertinência

$$\mu_S(y) = \mu_{R_1}(y) \nabla \mu_{R_2}(y) \nabla \dots \nabla \mu_{R_r}(y) \quad (17)$$

para cada $y \in Y$. Desta forma, pode-se usar a seguinte definição formal de sistema *fuzzy* (BANDO, 2002).

Definição 11: Um sistema *fuzzy* com r regras é o conjunto *fuzzy* S de Y representado pela função pertinência

$$\mu_S(y) = \nabla_{1 \leq i \leq r} [\mu_{A_{1i}}(x_1) \Delta \dots \Delta \mu_{A_{ni}}(x_n) \Delta \mu_{B_i}(y)], \quad (18)$$

para cada $y \in Y$.

Sendo assim, a função (24) indica com que grau cada $y \in Y$ pertence ao sistema *fuzzy* S , dependendo da entrada $x = (x_1, x_2, \dots, x_n) \in X^n$.

2.7.3 Controladores *Fuzzy*

Em geral, para um sistema *fuzzy* qualquer, a cada entrada *fuzzy* faz-se corresponder uma saída *fuzzy*. Os controladores *fuzzy* também têm essa característica. No entanto, se a entrada for um valor numérico (ponto de \mathbb{R}^n), espera-se que a saída também seja um valor numérico. Neste caso, um controlador *fuzzy* é uma função de \mathbb{R}^n em \mathbb{R}^n construída de alguma maneira específica. Os módulos seguintes indicam um roteiro para a construção desta função (BARROS; BASSANEZI, 2010).

Fuzzificação: Este estágio onde as entradas do sistema são modeladas por conjuntos *fuzzy* com seus respectivos domínios. É nele que justifica-se a grande importância do especialista do fenômeno a ser modelado. Juntamente com os especialistas, as funções de pertinência são formuladas para cada conjunto *fuzzy* envolvido no processo. Mesmo que a entrada seja um valor numérico, essa será fuzzificada por meio de sua função pertinência.

Base de Regras: Este pode ser considerado como um módulo que faz parte de “núcleo” do controlador *fuzzy*. Ele é composto pelas regras *fuzzy* e cada uma dessas regras é descrita na forma linguística “Se...Então” de acordo com as informações de um especialista. É neste ponto que as variáveis e suas classificações linguísticas são catalogadas e, em seguida, modeladas por conjuntos *fuzzy*, isto é, funções de pertinência.

Inferência *Fuzzy*: É neste módulo que cada proposição *fuzzy* é convertida matematicamente por meio das técnicas da teoria *fuzzy*. É onde se define quais t-normas, t-conormas e regras *fuzzy* serão utilizadas para se obter a relação *fuzzy* que modela a base de regras.

Este módulo tem tanta importância quanto o módulo da base de regras. Basicamente dele é que depende o sucesso do controlador *fuzzy*, já que ele fornecerá a saída *fuzzy* a ser adotada pelo controlador, a partir de cada entrada *fuzzy* (BARROS; BASSANEZI, 2010).

Defuzzificação: É o processo que permite representar a saída de um modelo linguístico *fuzzy* de forma quantitativa, ou seja, fornece um valor numérico representativo que captura o significado essencial de um conjunto *fuzzy*. Existem várias técnicas de defuzzificação e entre as mais usadas estão:

1. Média dos Máximos (MM): Fornece a média de todos os valores de saída que tenha os maiores graus de pertinência. Se “ y é A ” é uma conclusão *fuzzy* que deve ser defuzzificada. O método de defuzzificação MM é dado por

$$y^* = \frac{\sum_{x \in P} x}{m(P)} \quad (19)$$

onde P é o conjunto de todos os valores de saída com máximo grau de pertinência em A , ou seja, $P = \{x; \mu_A(x) = \sup_x \mu_A(x)\}$ e $m(P)$ é uma medida do conjunto P . Note que, se P é um intervalo, então, a técnica MM de defuzzificação fornece o ponto médio desse intervalo.

2. Centro de Área (CA): É a técnica de defuzzificação mais comumente usada. Ela também é conhecida como método do centro de gravidade ou centróide. Diferentemente do MM, a técnica do CA para calcular o valor numérico representativo considera todo o conjunto *fuzzy* de saída do sistema. O procedimento é similar ao usado para calcular o centro de gravidade em física, quando considera-se a função pertinência $\mu_A(x)$ como a densidade de massa de x (BEER; JOHNSTON, 1991). Por outro lado, o método do CA pode ser compreendido como uma média ponderada, onde $\mu_A(x)$ funciona como o peso do valor x . Se X é discreto, então a defuzzificação do conjunto *fuzzy* A é dada por

$$y^* = \frac{\sum_x \mu_A(x)x}{\sum_x \mu_A(x)}. \quad (20)$$

Se X é contínuo, então,

$$y^* = \frac{\int \mu_A(x)x \, dx}{\int \mu_A(x) \, dx}. \quad (21)$$

A principal desvantagem desse método é seu custo computacional, principalmente no caso em que X é contínuo.

A FIGURA 2.13 ilustra todas as etapas de um controlador *fuzzy*.




FIGURA 2.13 - Esquema geral de um controlador *fuzzy*
 FONTE: BARROS; BASSANEZI (2010)

2.7.4 Método de Inferência de Mamdani

O método de inferência de Mamdani (MAMDANI; ASSILIAN, 1975) é considerado o trabalho pioneiro na utilização dos conceitos da lógica *fuzzy* em sistemas de controle. Nesse trabalho, foi apresentado com eficiência uma aplicação de conceitos *fuzzy* para descrever as estratégias de controle linguisticamente, matematicamente imprecisas, utilizadas pelos operadores humanos no controle de um máquina a vapor.

Teoricamente, o método de inferência Mamdani utiliza um produto cartesiano *fuzzy* entre x_1, x_2, \dots, x_n e y para modelar matematicamente a base de regras e tem como operadores básicos de composição de inferência as aplicações máximo e mínimo dadas da seguinte forma:

- Em cada regra R_i da base de regras *fuzzy*, a condicional “Se x_1 é A_{1i} e ... e x_n é A_{ni} então y é B_i ” é modelada pela aplicação mínimo;
- Utiliza-se a t-norma \wedge (mínimo) para o conectivo lógico “e” e a t-conorma \vee (máximo) para o conectivo lógico “ou” que conecta as regras *fuzzy* da base de regras.

Desse modo, a base de regras \mathcal{M} é um subconjunto *fuzzy* de $X_1 \times X_2 \times \dots \times X_n \times Y$ cuja a função de pertinência é dada por

$$\mu_{\mathcal{M}}(y) = \bigvee_{1 \leq i \leq r} [\mu_{A_{1i}}(x_1) \wedge \dots \wedge \mu_{A_{ni}}(x_n) \wedge \mu_{B_i}(y)], \quad (22)$$

onde r é o número de regras que compõem a base de regras e, A_{1i}, \dots, A_{ni} e B_i são os subconjuntos *fuzzy* da regra i . Cada um dos valores $\mu_{A_{1i}}(x_1), \dots, \mu_{A_{ni}}(x_n)$ e $\mu_{B_i}(y)$ são interpretados como os graus com que x_1, x_2, \dots, x_n e y pertencem aos conjuntos *fuzzy* A_{1i}, \dots, A_{ni} e B_i , respectivamente, de maneira que \mathcal{M} nada mais é que a união *fuzzy* dos produtos cartesianos *fuzzy* entre os antecedentes e os consequentes de cada regra.

2.7.5 Medida de Possibilidade

Esta seção é uma releitura simplificada do capítulo 7 do livro (BARROS; BASSANEZI, 2010), destacando as diferenças básicas entre probabilidade e possibilidade, sendo este último conceito exclusivo da teoria *fuzzy*.

Intuitivamente, a probabilidade de um evento está relacionada à sua ocorrência. Já a pertinência relaciona-se com a identificação do mesmo. Num experimento aleatório, a incerteza termina a partir do momento em que o evento ocorreu. No caso *fuzzy*, a dúvida continua.

A medida de possibilidade foi desenvolvida por Zadeh (1978). Nesse artigo ele apresenta importantes discussões sobre qual é a forma mais adequada para se medir certos tipos de subjetividades qualitativas e como deve ser feita a sua formulação matemática. Para conseguir respostas consistentes ele se embasou na teoria de análise matemática através da Teoria da Medida. A noção de medida generaliza os conceitos habituais de comprimento, área, volume e etc.

A medida de probabilidade é um caso típico de uma medida, com a única restrição que seu contradomínio é o intervalo $[0,1]$. Como as funções de pertinência de conjuntos *fuzzy* têm esse contradomínio, a medida de probabilidade se torna a grande referência para definir uma medida na teoria *fuzzy*. A definição axiomática de probabilidade foi dada por Kolmogorov, a ideia central na definição é identificar cada evento como um subconjunto de um espaço amostral \mathcal{A} e associar a esse conjunto um número para indicar a chance de sua ocorrência. Dessa forma, a probabilidade é

uma função real de conjuntos que satisfaz certas propriedades. Uma forma simplificada de definir uma medida de probabilidade é dada por:

Definição 12: Uma função P definida em uma família \mathcal{A} de subconjuntos de Ω chamada de σ -álgebra, é uma probabilidade se:

$$P1. \forall A \in \mathcal{A} \Rightarrow 0 \leq P(A) \leq 1;$$

$$P2. P(\Omega) = 1;$$

$$P3. \text{ Se } A_1, A_2, \dots, A_i, \dots \in \mathcal{A} \text{ e } A_i \cap A_j = \emptyset, i \neq j, \text{ então } P(\cup_{i \in \mathbb{N}} A_i) = \sum_{i \in \mathbb{N}} P(A_i).$$

A propriedade P3 é denominada σ -aditividade. Esta propriedade é muito forte e acaba excluindo, da teoria de medidas, conceitos que parecem passíveis de mensuração. No caso de uma medida adequada para a teoria *fuzzy*, um dos objetivos apresentado pelos pesquisadores é a de flexibilizar a σ -aditividade. Alterando a propriedade P3 da definição de probabilidade surge uma medida que é amplamente aplicada em modelos utilizando conceitos *fuzzy*.

Definição 13 (Medida de Possibilidade): Uma função π definida em uma família \mathcal{A} de subconjuntos de Ω chamada de σ -álgebra, é uma medida de possibilidade se:

$$P1. \forall A \in \mathcal{A} \Rightarrow 0 \leq \pi(A) \leq 1;$$

$$P2. \pi(\emptyset) = 0 \text{ e } \pi(\Omega) = 1;$$

$$P3. \text{ Para qualquer família } \{A_{i \in \mathbb{J}}\} \text{ de subconjuntos de } \Omega \text{ tem-se}$$

$$\pi(\cup_{i \in \mathbb{J}} A_i) = \sup\{\pi(A_i); i \in \mathbb{J}\}.$$

A seguir serão apresentadas algumas reflexões sobre a diferença entre probabilidade e possibilidade.

Se em um determinado problema deseja-se obter o valor de um parâmetro ω_0 mas a única informação possível é que tal valor pertence a um determinado espaço Ω . Esse conhecimento parcial a respeito de ω_0 indica que algum modelo de incerteza deve ser usado para estimar ω_0 . Se por algum motivo sabe-se que todos os elementos de Ω são igualmente possíveis, então, pela metodologia Bayesiana, pode-se supor uma distribuição uniforme em Ω para se estimar ω_0 . Do ponto de vista de possibilidade essa informação pode ser descrita por meio de uma função pertinência onde os elementos de Ω têm o mesmo grau de pertinência.

Agora, se houver informações de gradualidades (dadas por um especialista, por exemplo), isto é, que há elementos mais plausíveis que outros em Ω , como tratar esta informação? Novamente, o tratamento Bayesiano sugere a adoção de uma distribuição de probabilidade (qual deve ser a adotada é uma questão a ser debatida) para, a partir daí, usá-la no sentido de se obter ω_0 .

Na teoria dos conjuntos *fuzzy*, a informação do especialista é tratada por meio de funções de pertinência onde ele indica qual dos elementos de Ω deve ter maior ou menor “peso”, de acordo com o seu conhecimento.

A adoção de um modelo matemático, concebido *a priori*, ou de um “construído” junto com um especialista, é uma diferença crucial entre a teoria de probabilidade e a de possibilidade no tratamento matemático de incertezas.

Em resumo, na teoria estocástica, as informações disponíveis são tratadas por meio de funções de densidade de probabilidade. Na teoria dos conjuntos *fuzzy*, tais informações são modeladas por funções de pertinência $\varphi: \Omega \rightarrow [0,1]$, que pode ser construídas segundo um especialista e $\varphi(\omega)$ indica a possibilidade de ω ser ω_0 . A função φ é vista como uma distribuição de possibilidade sobre Ω se satisfaz a definição:

Definição 14: Uma distribuição de possibilidade sobre o conjunto $\Omega \neq \emptyset$ é uma função $\varphi: \Omega \rightarrow [0,1]$ satisfazendo $\sup_{\omega \in \Omega} \varphi(\omega) = 1$.

Em geral, a densidade de distribuição de probabilidade está para a medida de probabilidade assim como a distribuição de possibilidade está para a medida de possibilidade.

Probabilidade e possibilidade têm naturezas distintas nas suas interpretações. Embora ambas se expressem por valores entre zero e um e ambas indiquem incertezas, a probabilidade mede a chance de um evento ocorrer, enquanto a possibilidade mede a tendência do evento ser verdadeiro.

Portanto, através desta seção, foi possível entender o funcionamento e o potencial da teoria de conjuntos *fuzzy*. Esta teoria é de grande utilidade neste trabalho, definindo funções que associam valores de $x \in \mathbb{R}^n$ com um $y \in \mathbb{R}^n$, através de variáveis linguísticas apresentadas por especialistas da área.

2.8 INFERÊNCIA BAYESIANA

Segundo Box e Tiao (1992) a inferência Bayesiana é um método estatístico que consiste em descrever as incertezas sobre quantidades de interesse de forma probabilística, tendo como característica a capacidade de combinar novas evidências com conhecimentos anteriores. As informações que se têm sobre uma quantidade desconhecida de interesse θ são fundamentais para reduzir a intensidade de incerteza e produzir melhores estimativas sobre θ .

2.8.1 Teorema de Bayes

Quando o valor exato de uma quantidade θ é desconhecido, a informação que tem-se sobre θ , resumida probabilisticamente por $P(\theta)$, pode ser aumentada através do conhecimento de informações aleatórias ($X = x$) relacionadas com θ . A regra de atualização que quantifica o aumento de informação é dada pelo Teorema de Bayes (JAMES, 2011)

$$P(\theta|x) = \frac{P(x, \theta)}{P(x)} = \frac{P(x|\theta)P(\theta)}{P(x)}, \quad (23)$$

onde o valor $1/P(x)$ independe de θ , funcionando apenas como uma função normalizadora de $P(\theta|x)$.

Para um valor fixo de x , a função $l(\theta; x) = P(x|\theta)$ fornece a *verossimilhança* de cada um dos possíveis valores de θ enquanto $P(\theta)$ é chamada distribuição *a priori* de θ . Estas duas informações são combinadas para gerar a distribuição *a posteriori* de θ , $P(\theta|x)$. Assim, a forma usual do teorema de Bayes é

$$P(\theta|x) \propto l(\theta; x)P(\theta), \quad (24)$$

(lê-se $P(\theta|x)$ é proporcional a $l(\theta;x)P(\theta)$, com $1/P(x)$ sendo a constante de proporcionalidade).

A utilização desta teoria se dá em muitas aplicações (exemplo: séries temporais), onde o maior interesse é na previsão do processo em pontos não observados do tempo ou espaço (PAULINO; TURKMAN; MURTEIRA, 2003).

A partir da Equação 24 a constante normalizadora da *posteriori* na Equação 25 pode ser recuperada por

$$P(x) = \int P(x, \theta) d\theta = \int P(x|\theta)P(\theta) d\theta = E_{\theta}[P(X|\theta)] \quad (25)$$

que é chamada distribuição preditiva. Assim, a distribuição *a posteriori* pode ser convenientemente resumida em termos de funções particulares do parâmetro θ , isto é

$$E[g(\theta)|x] = \int g(\theta)P(\theta|x) d\theta. \quad (26)$$

Desse modo, o problema geral da inferência Bayesiana consiste em calcular tais valores esperados segundo a distribuição *a posteriori* de θ . Portanto, a habilidade de integrar funções, muitas vezes complexas, é extremamente importante em inferência Bayesiana (EHLERS, 2011). Inferência exata somente será possível se estas integrais puderem ser calculadas analiticamente, caso contrário deve-se usar método de aproximações, o mais utilizado é dado pela simulação de Monte Carlo.

2.8.2 Simulação Monte Carlo

A ideia do método é justamente escrever a integral que se deseja calcular como um valor esperado. Considera-se o problema de calcular a integral de uma função $g(\theta)$ no intervalo (a, b) , isto é

$$I = \int_a^b g(\theta) d\theta. \quad (27)$$

Esta integral pode ser reescrita como

$$I = \int_a^b (b-a)g(\theta) \frac{1}{(b-a)} d\theta = (b-a)E[g(\theta)], \quad (28)$$

identificando θ como uma variável aleatória com distribuição $U(a, b)$. Assim, transforma-se o problema de avaliar a integral no problema estatístico de estimar uma média, $E[g(\theta)]$. Se ocorrer uma amostra aleatória de tamanho n , $\theta_1, \dots, \theta_n$ da distribuição uniforme no intervalo (a, b) tem-se também uma amostra de valores $g(\theta_1), \dots, g(\theta_n)$ da função $g(\theta)$ e a integral acima pode ser estimada pela média amostral

$$\hat{I} = (b-a) \frac{1}{n} \sum_{i=1}^n g(\theta_i). \quad (29)$$

Pode-se então usar o seguinte algoritmo:

1. Gerar $\theta_1, \dots, \theta_n$ da distribuição $U(a; b)$;
2. Calcular $g(\theta_1), \dots, g(\theta_n)$;
3. Calcular a média amostral $\bar{g} = \sum_{i=1}^n g(\theta_i)/n$;
4. Calcular $\hat{I} = (b-a)\bar{g}$.

No caso em que a integral é a esperança matemática de uma função $g(\theta)$ onde θ tem função de densidade $P(\theta)$ (Equação 26), a generalização é bem simples

$$I = \int_a^b g(\theta)P(\theta) d\theta = E[g(\theta)]. \quad (30)$$

Neste caso, pode-se usar o mesmo algoritmo descrito acima modificando-se o passo 1 para gerar $\theta_1, \dots, \theta_n$ da distribuição $P(\theta)$ e calcular

$$\hat{I} = \bar{g} = \frac{1}{n} \sum_{i=1}^n g(\theta_i). \quad (31)$$

Uma vez que as gerações são independentes, pela Lei Forte dos Grandes Números segue que \hat{I} converge quase certamente para I .

Porém, em muitas situações pode ser muito custoso ou mesmo impossível simular valores da distribuição *a posteriori*. Neste caso, recorre-se a métodos de reamostragem, que consistem em gerar valores em duas etapas. Na primeira etapa geram-se valores de uma distribuição auxiliar conhecida. Na segunda etapa utiliza-se um mecanismo de correção para que os valores sejam representativos (ao menos aproximadamente) da distribuição *a posteriori*.

Entre os métodos de reamostragem, o método de rejeição será tratado neste texto. Considera-se uma função de densidade auxiliar $q(\theta)$ da qual sabe-se gerar valores. A única restrição é que exista uma constante A finita tal que $P(\theta|x) < AP(\theta)$. O método de rejeição consiste em gerar um valor θ^* da distribuição auxiliar q e aceitar este valor como sendo da distribuição *a posteriori* com probabilidade $P(\theta^*|x)/AP(\theta^*)$. Caso contrário, θ^* não é aceito como um valor gerado da *posteriori* e o processo é repetido até que em valor seja aceito. O método funciona se ao invés da *posteriori*, que em geral é desconhecida, usar a sua função normalizada, isto é, $P(x|\theta)P(\theta)$ (EHLERS, 2011).

Tomando *a priori* $P(\theta)$ como densidade auxiliar a constante A deve ser tal que $P(x|\theta) < A$. Esta desigualdade é satisfeita quando toma-se A como sendo o valor máximo da função de verossimilhança, isto é, $A = P(x|\hat{\theta})$ onde $\hat{\theta}$ é o estimador de máxima verossimilhança de θ . Neste caso, a probabilidade de aceitação se simplifica para $P(x|\theta)/P(x|\hat{\theta})$.

Pode-se então usar o seguinte algoritmo para gerar valores da *posteriori*,

1. Gerar um valor θ^* da distribuição *a priori*;
2. Gerar $u \sim U(0,1)$;
3. Aceitar θ^* como um valor da *posteriori* se $u < P(x|\theta^*)/P(x|\hat{\theta})$, caso contrário rejeitar θ^* e retornar ao passo 1.

Uma dificuldade encontrada no método apresentado, é que os valores são gerados de forma independente e não há preocupação com a convergência do

algoritmo, bastando que o tamanho da amostra seja suficientemente grande. Por isso estes métodos são chamados *não iterativos*. No entanto, em muitos problemas pode ser bastante difícil, ou mesmo impossível, encontrar uma densidade de importância que seja simultaneamente uma boa aproximação da *posteriori* e fácil de ser amostrada.

Os métodos de Monte Carlos via cadeias de Markov (MCMC – *Monte Carlo Markov Chain*) são considerados alternativas para este problema (NOGUEIRA; SÁFADI; FERREIRA, 2004). A ideia ainda é obter uma amostra da distribuição a posteriori e calcular estimativas amostrais de características desta distribuição. A diferença é que, neste caso, aplica-se técnicas de simulação iterativa, baseadas em cadeias de Markov, e assim os valores gerados não são independentes.

2.8.3 Cadeias de Markov

Segundo Norris (1997) uma cadeia de Markov é um processo estocástico $\{X_0, X_1, \dots\}$ tal que a distribuição de probabilidade de X_t , dada as variáveis passadas, depende apenas de X_{t-1} , ou seja,

$$P(X_t \in A | X_0, \dots, X_{t-1}) = P(X_t \in A | X_{t-1}). \quad (32)$$

Desse modo, cada novo valor gerado pelo método MCMC depende do valor gerado anteriormente.

O algoritmo Metropolis-Hastings, desenvolvido inicialmente por Metropolis *et al.* (1953), e mais tarde, generalizado por Hastings (1970), é um métodos MCMV que possibilita a construção de uma cadeia de Markov, através da simulação de valores aleatórios de θ , que convergem para a distribuição *a posteriori* de interesse.

2.8.4 Algoritmos de Metropolis-Hastings

Os algoritmos de Metropolis-Hastings usam a mesma ideia dos métodos de rejeição vistos anteriormente, um valor é gerado de uma distribuição auxiliar e aceito com uma dada probabilidade. Estes mecanismos de correção garantem a convergência da cadeia para a distribuição de equilíbrio, que neste caso é a distribuição *a posteriori*.

Se a cadeia está no estado θ e um valor θ' é gerado de uma distribuição proposta $q(\cdot|\theta)$, esta pode depender do estado atual da cadeia, por exemplo uma distribuição normal centrada em θ . O novo valor θ' é aceito com probabilidade

$$\alpha(\theta, \theta') = \min \left(1, \frac{\pi(\theta')q(\theta|\theta')}{\pi(\theta)q(\theta'|\theta)} \right), \quad (33)$$

onde π é a distribuição de interesse.

Uma característica importante é que só precisa-se conhecer π parcialmente, isto é, a menos de uma constante já que neste caso a Equação 33 não se altera. Isto é fundamental em aplicações Bayesianas aonde não se conhece completamente a *posteriori*.

Em aplicações Bayesianas, é importante que a distribuição de interesse seja a própria *a posteriori*, isto é, $\pi(\theta) = P(\theta|x)$, assim, pelo teorema de Bayes, a probabilidade de aceitação assume a forma particular (EHLERS, 2011)

$$\begin{aligned} \alpha(\theta, \theta') &= \min \left(1, \frac{P(\theta'|x)q(\theta|\theta')}{P(\theta|x)q(\theta'|\theta)} \right) \\ &= \min \left(1, \frac{1/P(x)}{1/P(x)} \frac{P(x|\theta')P(\theta')}{P(x|\theta)P(\theta)} \frac{q(\theta|\theta')}{q(\theta'|\theta)} \right) \\ &= \min \left(1, \frac{l(\theta';x)P(\theta')}{l(\theta;x)P(\theta)} \frac{q(\theta|\theta')}{q(\theta'|\theta)} \right), \end{aligned} \quad (34)$$

onde $l(\theta; x)$ denota a função de verossimilhança de θ e $P(\theta)$ a distribuição *a priori* de θ .

Em termos práticos, o algoritmo de Metropolis-Hastings pode ser especificado pelos seguintes passos:

1. Inicializar o contador de iterações $t = 0$ e especificar um valor inicial $\theta^{(0)}$;
2. Gerar um novo valor θ' da distribuição $q(\cdot|\theta)$;
3. Calcular a probabilidade de aceitação $\alpha(\theta, \theta')$ e gerar $u \sim U(0, 1)$;
4. Se $u \leq \alpha$ então aceitar o novo valor e fazer $\theta^{(t+1)} = \theta'$, caso contrário rejeitar e fazer $\theta^{(t+1)} = \theta$;
5. Incrementar o contador de t para $t + 1$ e voltar ao passo 2.

Embora a distribuição proposta possa ser escolhida arbitrariamente, na prática deve-se tomar alguns cuidados para garantir a eficiência do algoritmo.

2.9 ÁRVORE DE FALHAS

Análise de árvore de falhas (FTA - *Fault Tree Analysis*) foi concebida e desenvolvida na *Bell Telephone Laboratories* por H.A. Watson em 1961, a técnica surgiu da necessidade de avaliar a confiabilidade de um sistema complexo associado ao controle de lançamento de mísseis guiados e de alcance intercontinental. Sua publicação apareceu pela primeira vez no relatório *Launch Control Safety Study, on Method of Inadvertent Launch Control Analysis*. Os resultados foram muito próximos aos dados observados e o estudo forneceu confiança suficiente e encorajamento para, utilizar esta técnica no projeto de Minuteman II (MISRA, 1992).

Após o trabalho inicial no *Bell Telephone Laboratories*, a análise de árvore de falhas continuou a ser usada na *Boeing Company*, onde foi aplicada nas técnicas de simulação de aeronaves tripuladas. Os relatórios de árvore de falhas do Minuteman II foram publicados pela Boeing e AVCO em março 1963 e janeiro 1964, respectivamente. Mais tarde, em junho de 1965, a empresa Boeing e Universidade de Washington patrocinaram um simpósio sobre a segurança de sistema, em Seattle, onde uma série de trabalhos sobre FTA foram apresentados (MISRA; WEBER, 1989).

Outro uso extensivo e prático de análise de árvore de falhas (FTA) foi feita pelo prof. N. Rasmussen, enquanto preparava o documento histórico, WASH-1400. Esta foi

a primeira tentativa científica para fornecer uma análise quantitativa de risco associado com usinas nucleares. WASH-1400 utilizou a análise de árvore de falhas para estimar a probabilidade de cada evento no caminho do acidente, e assim, gerar probabilidade total de vários tipos de acidentes. A análise da árvore de falhas do prof. Rasmussen cobriu todo o sistema de segurança envolvido na redução do efeito da perda de refrigeração em acidentes grandes e pequenos. A partir desse estudo, a análise da árvore de falhas deu uma compreensão muito útil no funcionamento dos sistemas utilizados para a redução dos efeitos de acidentes (SIMÕES FILHO, 2006).

Desde então, os conceitos e as técnicas utilizadas na análise de árvore de falhas continuaram a ser desenvolvidas, e hoje é considerada como uma metodologia estabelecida para os estudos de segurança e confiabilidade de sistemas grandes e complexos.

2.9.1 Características de uma Árvore de Falhas

A FTA é um processo dedutivo que consiste na construção de um diagrama lógico (árvore de falhas), partindo de um evento indesejado, chamado de “evento topo”, buscando as possíveis causas de tal evento. O processo segue investigando as sucessivas combinações de falhas dos componentes até atingir as chamadas falhas básicas (ou eventos primários da FT), as quais constituem o limite de resolução da análise.

A principal função da FTA é traduzir um processo físico em um diagrama lógico estruturado, chamado árvore de falhas, em que eventos mais simples conduzem a um evento mais complexo.

A popularidade da FTA se dá devido as diversas vantagens encontradas:

- (i) Fornece um registro organizado de todos os eventos que contribuem para a falha;
- (ii) Apresenta uma estrutura gráfica que possibilita várias avaliações (qualitativas e quantitativas);
- (iii) Destaca os pontos fracos de um sistema;
- (iv) Prioriza os principais contribuintes para a falha.

A árvore de falhas é uma representação gráfica para identificar como as combinações dos eventos básicos, podem conduzir a um resultado não desejado (SANTOS, 2006). Provê uma estrutura com a qual pode considerar a probabilidade destas ocorrências. Isto é útil onde a contribuição de um evento particular pode ser importante, onde deseja-se conhecer como a probabilidade do evento topo é afetada pela probabilidade dos vários fatores contribuintes. Usando procedimentos da Álgebra Booleana, pode-se idealmente derivar a probabilidade do evento topo. A hipótese é que uma vez que se tenha razoável ideia a respeito da probabilidade de ocorrência dos fatores que contribuem potencialmente, deve-se ter uma melhor ideia a respeito do que focar na tomada de decisão e ação corretiva que se apresente.

Uma análise de árvore de falhas é normalmente dividida nas seguintes etapas:

Etapa 01: Definição do Sistema;

Etapa 02: Definição do Evento Topo;

Etapa 03: Construção da Árvore de Falhas;

Etapa 04: Avaliação Qualitativa;

Etapa 05: Avaliação Quantitativa;

Etapa 06: Avaliação da Importância dos eventos básicos;

Etapa 07: Análise dos resultados obtidos;

Etapa 08: Conclusões.


O diagrama lógico de uma FT é construído através de símbolos lógicos descritos a seguir.

2.9.2 Elementos de uma Árvore de Falhas


Para este estudo vai ser utilizado apenas quatro símbolos para a construção da árvore de falhas:



- Evento Topo ou Intermediário: Evento que pode ser decomposto por eventos antecedentes.



- Evento Básico: Evento que não é mais necessária a decomposição em eventos antecedentes. De modo geral, ocorre quando o analista dispõe dos dados básicos de falhas.



- Porta Lógica "E": O evento de saída ocorre somente se todos os eventos de entrada ocorrem.



- Porta Lógica "OU": O evento de saída ocorre somente se um ou mais dos eventos de entrada ocorrem.

Uma vez construída a árvore de falhas de um sistema para a análise do evento de topo especificado, é possível através de regras da álgebra booleana efetuar avaliações qualitativas e quantitativas para um melhor entendimento do evento indesejado. Para árvores de falhas pequenas e simples isto pode ser feito manualmente, para sistemas grandes e complexos são necessários códigos computacionais (NASA, 2002).

A FIGURA 2.14 mostra um exemplo simplificado de uma árvore de falhas.

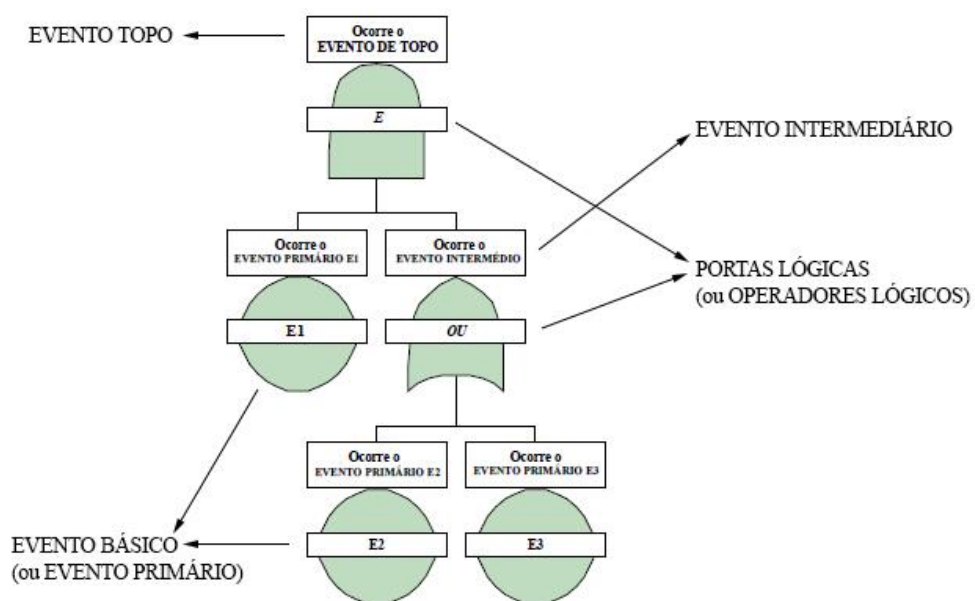


FIGURA 2.14 - Exemplo de um diagrama de árvore de falhas
FONTE: SANTOS (2006)

2.9.3 Análise Qualitativa

A análise qualitativa da árvore de falhas visa, por um lado, apresentar informações sobre a importância dos eventos básicos e, por outro, identificar as combinações de eventos básicos que contribuem para o evento de topo, garantindo dessa forma árvores de falhas mais simples porém equivalentes às construídas inicialmente.

Existem diversas técnicas que possibilitam uma análise qualitativa de uma FT, convertendo seu formato gráfico em equações por meio de álgebra booleana. A técnica dos conjuntos de cortes mínimos (MCS – *Minimal Cut Sets*), é considerada uma das mais utilizadas na análise de árvore de falhas (U. S. NUCLEAR REGULATORY COMMISSION, 1981).

2.9.4 Conjunto de Cortes Mínimos

Um conjunto de cortes (CS - *Cut Set*) corresponde a uma coleção de eventos básicos, de tal modo, que se estes eventos ocorrerem então é certo que também ocorre o evento topo.

A transformação da árvore para a forma booleana possibilita a determinação dos conjuntos mínimos de cortes. Um MCS constitui um conjunto mínimo de eventos básicos, ou combinações destes, que, quando ocorrem, originam a ocorrência do evento topo, ou seja, um conjunto de cortes é considerado mínimo se não puder ser reduzido sem perder o status de conjunto de cortes.

A técnica para determinar o MCS de uma árvore de falha, consiste em aplicar conceitos da álgebra booleana para transformar seu formato gráfico em equações. As portas lógicas E e OU são traduzidas através de regras da lógica e álgebra booleana (QUADRO 1).

Desse modo, o evento topo é descrito por uma equação desenvolvida através da interpretação da porta lógica (E ou OU) que o conecta aos seus eventos antecedentes, em seguida, cada evento que aparece na equação é decomposto também pelos seus eventos antecedentes usando a regra adequada para a porta lógica

que os conecta a esses eventos, e assim por diante, até que o evento topo seja descrito em uma equação que só tenha eventos básicos (GUIMARÃES, 1997).

Portas Lógicas	Teoria de Conjuntos	Álgebra Booleana
$X \text{ E } Y$	$X \cap Y$	$X.Y$
$X \text{ OU } Y$	$X \cup Y$	$X + Y$

QUADRO 1 - Portas lógicas representadas pela álgebra booleana

FONTE: O autor

Em seguida, a equação encontrada pode ser simplificada através da aplicação das leis da álgebra booleana QUADRO 2:

Leis	Representação
Comutativas	$X.Y = Y.X$ $X + Y = Y + X$
Associativas	$X.(Y.Z) = (X.Y).Z$ $X + (Y + Z) = (X + Y) + Z$
Distributiva	$X.(Y + Z) = X.Y + X.Z$
Inalterabilidade	$X.X = X$ $X + X = X$
Absorção	$X + X.Y = X$
Complementaridade	$X + X' = \Omega$ $(X')' = \Omega$
De Morgan	$(X.Y)' = X' + Y'$ $(X + Y)' = X'.Y'$

QUADRO 2 - Leis da álgebra booleana

FONTE: O autor

Aplicando as leis apresentadas, é possível simplificar a equação eliminando:

- (i) Todos os parênteses da expressão;
- (ii) Os conjuntos de cortes repetidos;
- (iii) Os conjuntos supérfluos.

Assim, o evento topo T é representado por uma equação da forma

$$T = C_1 + C_2 + \dots + C_n, \quad (35)$$

onde cada C_i , $i = 1, 2, \dots, n$, é um conjunto de corte mínimo que corresponde à operação booleana (.) de uma determinada sequência de eventos básicos, ou seja, a Equação 35 apresenta uma combinação simplificada de alguns eventos básicos, que garante a ocorrência do evento topo quando esses eventos básicos ocorrerem.

2.9.5 Análise Quantitativa

É comum em uma análise de árvore de falhas que a análise quantitativa seja feita atendendo aos resultados obtidos na análise qualitativa. Os resultados podem ser a estimativa numérica da probabilidade de ocorrência do evento topo, e também a mensuração da importância que cada evento básico tem na contribuição do evento topo.

Para isso, é necessário conhecer as estimativas confiáveis das probabilidades de ocorrência dos eventos básicos que compõem os conjuntos de cortes mínimos (U. S. NUCLEAR REGULATORY COMMISSION, 1981).

A teoria matemática de probabilidade se relaciona completamente com os fundamentos da lógica booleana utilizados na análise qualitativa de uma árvore de falhas (SANTOS, 2006). Enquanto a lógica booleana é utilizada para expressar o evento topo na forma de uma equação que possibilita uma avaliação qualitativa, a teoria probabilística permite uma análise quantitativa do evento topo.

Para uma análise de árvore de falhas, utiliza-se as relações básicas da probabilidade que estão relacionadas aos conectivos lógicos apresentados anteriormente, são eles:

União de eventos:

$$P(X_1 \cup X_2) = P(X_1) + P(X_2) - P(X_1 \cap X_2). \quad (36)$$

Intersecção de eventos:

$$P(X_1 \cap X_2) = P(X_1) \cdot P(X_2|X_1), \quad (37)$$

onde $P(X_2|X_1)$ é a probabilidade condicional de ocorrer o evento X_2 sabendo que ocorreu o evento X_1 .

Alguns resultados dentro da teoria de probabilidade auxiliam para uma melhor análise do evento topo:

(i) Se os eventos X_1 e X_2 são mutuamente exclusivos, então $P(X_1 \cap X_2) = 0$ e tem-se pela Equação 36 que $P(X_1 \cup X_2) = P(X_1) + P(X_2)$, logo, se todos os eventos X_1, X_2, \dots, X_n são mutuamente exclusivos, então

$$P(X_1 \cup X_2 \cup \dots \cup X_n) = P(X_1) + P(X_2) + \dots + P(X_n); \quad (38)$$

(ii) Se os eventos X_1 e X_2 são independentes, então $P(X_2|X_1) = P(X_2)$, assim $P(X_1 \cap X_2) = P(X_1).P(X_2)$, logo, se todos os eventos X_1, X_2, \dots, X_n são independentes, então

$$P(X_1 \cap X_2 \cap \dots \cap X_n) = P(X_1).P(X_2) \dots P(X_n); \quad (39)$$

(iii) Pela lei De Morgan na teoria de conjuntos, $X_1 \cup X_2 = (X_1' \cap X_2')'$, assim, tem-se que $P(X_1 \cup X_2) = 1 - P(X_1' \cap X_2')$, e se assumir a independência dos eventos, tem-se que $P(X_1 \cup X_2) = 1 - (1 - P(X_1))(1 - P(X_2))$. Desse modo,

$$P(X_1 \cup X_2 \cup \dots \cup X_n) = 1 - \prod_{i=1}^n (1 - P(X_i)). \quad (40)$$

A Equação 39 determinada a partir da técnica de conjunto de cortes mínimos, descreve o evento topo T , numa equação booleana. Aplicando as regras de probabilidades apresentadas, pode-se calcular o valor exato da probabilidade do evento topo a partir das probabilidades dos eventos básicos (GUIMARÃES; LAPA, 2007).

Assim, aplicando a Equação 40 e a Equação 39 para o cálculo da probabilidade do evento topo $P(T)$, tem-se que

$$P(T) = \sum_{i=1}^n P(C_i) - \sum_{i < j} P(C_i \cdot C_j) + \sum_{i < j < k} P(C_i \cdot C_j \cdot C_k) - \dots + (-1)^{n+1} P(C_1 \dots C_k). \quad (41)$$

onde C_i é um conjunto de corte mínimo.

A partir dessa equação, pode-se demonstrar a seguinte desigualdade

$$\sum_{i=1}^n P(C_i) - \sum_{i < j} P(C_i \cdot C_j) \leq P(T) \leq \sum_{i=1}^n P(C_i). \quad (42)$$

Portanto, tem-se que a $\sum_{i=1}^n P(C_i)$ representa um limite superior de $P(T)$ que se denota por aproximação de eventos raros. Assim, adota-se para o cálculo da probabilidade do evento topo a aproximação

$$P(T) \approx \sum_{i=1}^n P(C_i). \quad (43)$$

Essa aproximação se baseia no fato de que a probabilidade de ocorrer dois eventos simultaneamente é menor ou igual que as probabilidades individuais de ambos.

Em seguida, será necessário calcular a probabilidade de cada conjunto de corte mínimo, $P(C_i)$. Como cada C_i é composto por um número de intersecções de eventos básicos, ou seja,

$$C_i = X_{1i} \cdot X_{2i} \dots X_{mi}. \quad (44)$$

onde $X_{1i} \cdot X_{2i} \dots X_{mi}$ são alguns eventos básicos da árvore de falhas. Se os eventos básicos forem independentes, tem-se que

$$P(C_i) = P(X_{1i}) \cdot P(X_{2i}) \dots P(X_{mi}). \quad (45)$$

Assim, de modo geral, quando as probabilidades dos eventos básicos são baixas, então a aproximação por *eventos raros* resulta em uma boa estimativa para a probabilidade do evento topo.

2.9.6 Medidas de Importância

Um dos principais atributos da análise de árvore de falhas é o fato de poder estimar quantitativamente a confiabilidade de um sistema. A avaliação quantitativa dos conjuntos de cortes mínimos permite detectar certas vulnerabilidades do sistemas. No entanto, existe um conjunto de ferramentas numéricas, denotadas de medidas de importância, que permitem avaliar a contribuição dos eventos básicos em relação ao evento topo. Desse modo, avalia-se quantitativamente a importância estrutural das árvores de falhas (SANTOS, 2006).

A importância de uma componente depende da função que esta cumpre no desempenho e na confiabilidade do sistema. É útil, nem sempre necessário, dispor de meios numéricos que permitam compreender qual é a importância no sistema dos eventos básicos. Este ponto é particularmente relevante, pois possibilita melhorar a confiabilidade de sistemas através do aumento da confiabilidade das componentes mais relevantes (FURUTA; SHIRAISHI, 1984).

O QUADRO 3 indica uma lista de possíveis medidas de importância, apresentando a sua expressão uma pequena descrição do seu significado. Todas as medidas de importância descritas são utilizadas em eventos básicos.

Para melhor entendimento do QUADRO 3 é importante esclarecer algumas nomenclaturas apresentadas. Assim, P_T e P_E correspondem às probabilidades (ou possibilidades *fuzzy*) de ocorrer, respectivamente, o evento topo T e o evento básico E . As expressões $P_T(E = 0) = P(T|P(E) = 0)$ e $P_T(E = 1) = P(T|P(E) = 1)$ representam a probabilidade (ou possibilidades *fuzzy*) do evento básico E é, respectivamente, nula (mínima) ou unitária (máxima).

As medidas de importância podem ser particularmente valiosas em sistemas complexos e com um número elevado de eventos básicos.

continua

Medida de Importância	Expressão	Descrição
<i>Fussel-Vesely</i> (FV)	$FV_E = \frac{P_T - P_T(E = 0)}{P_T}$	Medida relativa da contribuição do evento básico E para a probabilidade do evento topo T

conclusão

<i>Birnbaum</i> (BE)	$BE_E = P_T(E = 1) - P_T(E = 0)$	Medida da sensibilidade da probabilidade P_T no que diz respeito à variabilidade da probabilidade de E
Criticalidade (Cr)	$Cr_E = \frac{P_T(E = 1) - P_T(E = 0)}{P_T}$	Probabilidade do evento ser crítico dado que ocorreu o evento topo
Valor de redução do risco (<i>Risk Reduction Worth – RRW</i>)	$RRW_E = \frac{P_T}{P_T(E = 0)}$	Mostra o benefício relativo para a probabilidade P_T se a probabilidade do evento E for nula
Valor obtido do risco (<i>Risk Achievement Wort – RAW</i>)	$RAW_E = \frac{P_T(E = 1)}{P_T}$	Mostra o benefício relativo para a probabilidade P_T se a probabilidade do evento E for unitária

QUADRO 3 - Exemplos de medidas de importância
 FONTE: SANTOS (2006)

3 REVISÃO DE LITERATURA

Neste capítulo serão apresentados o desenvolvimento e alguns dos principais resultados descritos na literatura, envolvendo análises de árvore de falhas através da utilização de conceitos da teoria *fuzzy*. A união da teoria de análise de árvore de falhas com a teoria *fuzzy* deu início a um estudo denominando análise *fuzzy* de árvore de falhas (FFTA - *Fuzzy Fault Tree Analysis*). O estudo apresentado neste capítulo foi baseado principalmente em artigos publicados a partir 1983, onde a FFTA teve suas primeiras aplicações. A atenção em segurança de usinas nucleares e indústria aeroespaciais foram os grandes campos para o desenvolvimento da teoria.

3.1 ANÁLISE FUZZY DE ÁRVORE DE FALHAS (FFTA)

A análise de confiabilidade de um sistema (mecânico, elétrico, computacional, químico e outros) requer uma adequada compreensão das relações lógicas entre subsistemas e os seus modos de falhas associados. Foi visto anteriormente que a análise de árvore de falhas (FTA) é um método amplamente utilizado para a análise lógica da falha na confiabilidade de um sistema. No entanto, a aplicação da FTA convencional tem algumas deficiências, por exemplo, em lidar com incertezas, permitir o uso de variáveis linguísticas no modelo. Assim, a teoria *fuzzy* surge como uma proposta para superar estas limitações da FTA convencional, fornecendo um quadro em que as noções básicas de similaridades, incertezas e subjetividades podem ser modeladas de forma eficaz (MAHMOOD *et al.*, 2013).

3.2 MOTIVAÇÃO PARA O USO DA FFTA

Em uma análise quantitativa de uma FTA convencional, as probabilidades de falhas são consideradas com um valor exato, ou seja, um único valor estimado. No entanto, é muito difícil calcular uma taxa de falha ou uma probabilidade exata devido

a vários fatores, e entre eles, a insuficiência de dados de falhas e a própria incerteza em relação ao conceito do que vem a ser uma falha (DESHPANDE, 2011).

Na ausência de dados precisos, muitas vezes a experiência de peritos da área, por exemplo, projetistas, operadores, engenheiros ou consultores, fornecem um bom banco de dados para apoiar uma estimativa grosseira necessária. Além disso, a ocorrência de dados inadequados fazem com que seja difícil de determinar a probabilidade de uma forma objetiva, assim, o julgamento humano através de variáveis linguísticas se torna essencial. Com isso, tende-se a aplicar expressões linguísticas naturais, como “muito baixo”, “alto”, “bastante elevado”, “bem perigoso”, para descrever a chance de ocorrência de eventos. Em um monitoramento de falhas, muitos sintomas são detectados através de observações feitas pelo pessoal responsável pela inspeção, e podem ser obtidas através de ruídos acústicos, oscilações ou impressões ópticas como mudança de cores ou fumaça. Entretanto, estes sintomas sugerem conceitos vagos com frequência, o que normalmente só pode ser expressado na forma de medidas qualitativas e variáveis linguísticas. Modelos matemáticos convencionais apresentam dificuldades para lidar com estas variáveis linguísticas de forma natural devido à grande quantidade de imprecisões. Desse modo, uma taxa de falha gerada através de uma análise quantitativa convencional pode não representar a devida confiabilidade do sistema (MAHMOOD *et al.*, 2013). Mesmo os modelos quantitativos mais sofisticados, precisos e bem construídos podem levar a resultados enganosos, se as incertezas não são tratadas em algum nível. Além disso, uma FTA convencional não permite a alocação de um grau de incerteza na modelagem dos eventos básicos (DING; YU, 2005).

Portanto, foi necessário o desenvolvimento de uma nova metodologia para capturar a subjetividade e a imprecisão dos dados de falha, para ser usado no FTA convencional. A utilização da teoria dos conjuntos *fuzzy* foi proposta em vários trabalhos, onde é aplicada para fornecer uma maneira de se chegar às conclusões definitivas a partir de informações vagas, ambíguas ou imprecisas. A FIGURA 3.1 indica o crescimento do número de artigos publicados nos últimos 30 anos no campo de FFTA, baseado nos dados bibliográfico da Scopus (banco de dados de resumos e citações de artigos para jornais/revistas acadêmicos) (MAHMOOD *et al.*, 2013).

Entre os principais estudos sobre FFTA, destaca-se o trabalho de Tanaka *et al.* (1983), que foi um dos pioneiros na aplicação de conceitos da teoria *fuzzy* em uma análise de árvore de falhas, onde é utilizado o princípio de extensão *fuzzy* para

calcular a probabilidade do evento de topo que é dado por um número *fuzzy*. Outros artigos também tiveram resultados satisfatórios, como o de Misra e Weber (1989), que usaram os “operadores máximo e mínimo” para avaliar o início do evento em termos das “possibilidades” dos eventos básicos, e ilustraram um processo para analisar um núcleo de resfriamento de emergência do sistema de um reator nuclear.




FIGURA 3.1 - Distribuição por anos do número de publicações de artigos com o tema "Fuzzy Fault Tree" na Scopus.

FONTE: MAHMOOD *et al.* (2013)

Onisawa, Takehisa e Kacprzyk (1995) desenvolveram um método simples para FFTA com base no método dos cortes mínimos, também conhecida como a resolução identidade. Sawyer (1994) utilizou o método de corte para calcular a probabilidade de falha do evento topo em FFTA de sistemas mecânicos. Uma análise de árvore de eventos, com base na utilização de instruções verbais para caracterizar a probabilidade dos eventos, foi apresentada por Kenarangui (1991).

O método *fuzzy* pode ser a única maneira quando tem-se pouca informação quantitativa disponível sobre as variações dos parâmetros, neste caso as probabilidades de falhas dos eventos básicos são tratados como números *fuzzy* (DING; YU, 2005). Lin e Wang (1998) combinaram a teoria de conjuntos *fuzzy* com informações de especialista para a obtenção de dados a respeito do estudo para calcular a probabilidade de falha dos eventos básicos de um sistema de perfuração de robô, com base em números *fuzzy* triangulares. Diversos outros trabalhos sobre FFTA são citados nos estudos de Deshpande (2011) e Mahmood *et al.* (2013).

Em seguida, serão apresentadas algumas metodologias desenvolvidas para uma FFTA, mostrando como conceitos da teoria *fuzzy* pode auxiliar em uma análise de árvore de falhas.

3.3 PROBABILIDADE FUZZY

Probabilidade *Fuzzy* é dada por um número *fuzzy* (TANAKA *et al.*, 1983), pois assim, pode descrever as incertezas sobre a probabilidade exata de uma falha. Para poder representar a probabilidade de um evento, o número *fuzzy* será definido entre zero e um. Embora o trabalho pioneiro de Tanaka *et al.* (1983) tenha usado um número *fuzzy* trapezoidal, a maioria dos pesquisadores têm utilizado o número *fuzzy* triangular (NFT).

Para utilizar a probabilidade *fuzzy*, é preciso a conversão de um valor exato em um número *fuzzy*. Os números *fuzzy* podem ser gerados de diversos modos, como a elicitacão de conhecimento especializado (método 3σ), que é utilizado quando não há dados estatísticos suficientes para determinar a taxa de falha como um valor exato (CAI, 1996). Este método consiste em utilizar a experiência de três especialistas. Cada perito vai estimar um valor da probabilidade dos eventos de falhas. O valor médio dos valores estimados será denotado por b e o desvio-padrão por σ . Aceita-se que os valores de probabilidade supostos pertencem a uma distribuição normal, e assim, de acordo com o método 3σ , o valor de probabilidade do evento falha está localizado no intervalo $[b - 3\sigma, b + 3\sigma]$, desse modo, considera-se o número *fuzzy* triangular $\tilde{A} = (b - 3\sigma, b, b, b + 3\sigma)$ como sendo a probabilidade *fuzzy* de ocorrência do evento (CAI, 1996). Outra forma que pode ser considerada é a utilização de porcentagem da média para definir os limites inferior e superior do intervalo de definição do número *fuzzy* (por exemplo, $\pm 15\%$), assim o número *fuzzy* considerado é dado por $\tilde{A} = (b - 0,15b, b, b, b + 0,15b)$ (KUMAR; BORM; KUMAR, 2012).

3.4 USO DE VARIÁVEIS LINGUÍSTICAS

Variáveis linguísticas como o próprio nome sugere, são variáveis cujos valores são palavras ou frases em uma língua natural. Por exemplo, “nível de atenção” pode ser uma variável linguística cujos valores pertencem ao conjunto de termos: “muito baixo”, “baixa”, “médio”, “alta” e “muito alto”. Foi visto que estes termos podem ser definidos como um conjunto *fuzzy* (BARROS, 1997). Cada valor de uma variável linguística representa uma distribuição de possibilidade. Essas distribuições de possibilidade podem ser computadas a partir das distribuições de possibilidade dos eventos básicos. Os valores do intervalo podem ser expressos em termos de um único par de números $[a, b]$, isto é, um $0 \leq a \leq p \leq b \leq 1$, em que p indica a confiabilidade probabilística (CAI, 1996).

A principal razão para o tratamento do valor da confiabilidade probabilística por um número *fuzzy* é a falta de dados observados para o comportamento de falha do sistema. Além disso, dados inadequados fazem com que seja difícil de determinar a probabilidade de uma forma objetiva. Assim, os julgamentos humanos por variáveis linguísticas são muitas vezes utilizados.

O conceito de variável linguística é muito útil, para lidar com situações que são complexas ou subjetivas. Mas os caminhos matemáticos convencionais não conseguem lidar com expressão linguística naturais de forma eficiente. Portanto, a teoria dos conjuntos *fuzzy*, como foi mostrada, consegue transformar esses termos linguísticos em representações matemáticas. Em FTA convencional, não é possível refletir uma situação exata da segurança do sistema, o método *fuzzy* modelando variáveis linguísticas pode ser o único recurso quando existe pouca informação quantitativas (DING; YU, 2005).

Através de um modelo *fuzzy*, o analista pode usar variáveis linguísticas para avaliar os acontecimentos de uma forma natural, e a possibilidade de falhas dos eventos pode ser aproximada, pelas suas funções de pertinência. Se tornando adequado para o tratamento de subjetividade obtida em engenharia de segurança do sistema (LIN; WANG, 1998).

O primeiro passo para usar as variáveis linguísticas em FTA foi dado por Weber (1994), onde é desenvolvido e aplicado um método de intervalo para a análise da árvore de falhas. Ele aplica uma abordagem analítica simplificada que utiliza termos

linguísticos no lugar de valores de probabilidade. Os termos linguísticos “extremamente remota”, “remoto” e “frequente” foram descritos por números *fuzzy*. Mais recentemente, tem-se o trabalho (REN; KONG, 2011), onde uma nova abordagem de análise *fuzzy* de árvore de falhas se baseia em um sistema especialista *fuzzy*. Os autores aplicaram a teoria *fuzzy* para representar o grau dos eventos básicos, em seguida, de acordo com o processo de sistema especialista *fuzzy* calcularam a probabilidade do evento de topo.

O histórico do processo de diagnóstico, na forma de manutenção, reparos, falhas anteriores, tempo de vida e medidas de carga, constitui uma fonte adicional de informação. Os dados estatísticos obtidos a partir da experiência com processos similares podem ser adicionados. Sintomas heurísticos podem ser representados como variáveis linguísticas (por exemplo, “pequeno”, “médio” e “grande”) ou como números vagos (por exemplo, em torno de um determinado valor) (ISERMANN, 1997).

3.5 OPERADORES FUZZY

Supondo-se que os números *fuzzy* triangulares P_1 e P_2 podem ser expressos separadamente por (a_1, b_1, c_1) e (a_2, b_2, c_2) as operações algébricas sobre os números *fuzzy* P_1 e P_2 através das portas lógicas “E” e “OU” são dados por:

1. Operador *Fuzzy* para a Porta Lógica “E”: Foi visto anteriormente que em uma FTA convencional a probabilidade de eventos ligado por uma porta “E” é calculada por

$$P_E = \prod P_i, \quad (46)$$

como no caso *fuzzy*, a probabilidade é um número *fuzzy*, o produto utilizado é dado pelo produto de números *fuzzy*, porém esta expressão exige muito esforço computacional. Para contornar este problema Tanaka *et al.* (1983), mostra que a fórmula

$$P_E = \prod P_i = [\prod a_i, \prod b_i, \prod b_i, \prod c_i], \quad (47)$$

é uma boa aproximação para o produto de números *fuzzy* triangulares. Assim, a expressão (47) passa a ser utilizada amplamente com a operação para a porta lógica “E” no caso de probabilidades *fuzzy*.

2. Operador *Fuzzy* para a Porta Lógica “OU”: Foi visto anteriormente que em uma FTA convencional a probabilidade de eventos ligado por uma porta “OU” é calculada por

$$P_{OU} = 1 - \prod (1 - P_i), \quad (48)$$

analogamente ao caso da porta “E”, é utilizada para a porta “OU” a aproximação

$$\begin{aligned} P_{OU} &= 1 - \prod (1 - P_i) \\ &= 1 - [\prod (1 - a_i), \prod (1 - b_i), \prod (1 - b_i), \prod (1 - c_i)]. \end{aligned} \quad (49)$$

Nos dois casos, o desenvolvimento da fórmula leva em conta o fato dos eventos serem independentes. No caso de eventos dependentes, poucos resultados são encontrados. Mao *et al.* (2010) utiliza os operadores $P_E = \min(P_1, \dots, P_n)$ e $P_{OU} = \max(P_1, \dots, P_n)$ quando existe a dependência entre os eventos.

Hadipriono, Fabian e Fujino (1994) desenvolveram duas novas portas lógicas para fins de FFTA, média *fuzzy* e operação soma *fuzzy*. Média *fuzzy* é uma operação entre “E” e “OU” e a operação soma *fuzzy* produz um efeito de acumulação de valores de entrada. Novas portas lógicas são definidas para tentar melhorar a avaliação da possibilidade de falha do sistema, tentando modelar as possibilidades otimista e pessimista do acidente.

Embora em uma análise da árvore de falhas, as portas “E” e “OU” têm sido usadas como portas típicas, muitas vezes se torna difícil modelar toda uma estrutura do sistema somente com estas duas portas. Em muitos casos, o conhecimento exato sobre o mecanismo de falha do sistema não está disponível (MAHMOOD *et al.*, 2013). Pan e Yun (1997) aplicaram a teoria dos conjuntos *fuzzy* para modelar a estrutura de

um sistema, e assumiram que as portas lógicas são modeladas por uma relação *fuzzy*, devido ao fato de muitas vezes ser impossível obter uma relação exata entre os componentes do sistema.

3.6 MEDIDAS DE IMPORTÂNCIA *FUZZY*

Em FTA convencional, o conceito de importância é utilizado para avaliar o quanto um evento básico contribui para a falha do evento topo. A medida de importância é determinável, não só para os eventos básicos, mas também para todos os eventos em qualquer nível da árvore de falhas. Isto fornece um significado numérico de todos os elementos de árvore de falhas que permite dar-lhes prioridade (MISRA, 1992). A medida de importância também é usada para otimizar o projeto do sistema e sua confiabilidade. Além disso, este parâmetro também fornece informações valiosas para melhorar o diagnóstico de falhas de sistemas complexos e fornece uma orientação razoável para manutenção.

Os valores de importância são medidos pelo uso de informações dos eventos básicos e superiores (GUIMARÃES; LAPA, 2007). No entanto, informações a base de probabilidade podem ser insignificantes para um caso em que a ocorrência de um evento de base pode ser especificado de forma imprecisa. Isto significa que, se o estado de um evento de base é expressado por um evento impreciso, pode não ser possível identificar a importância de cada caso, com base em apenas uma informação de probabilidade (MISRA, 1993).

Portanto, Furuta e Shiraishi (1984) propuseram a importância *fuzzy* (FI) para esclarecer as ambiguidades envolvidas no processo de certificação da ocorrência de eventos básicos utilizando os operadores *fuzzy* max/min e uma técnica de medida chamada de integral *fuzzy*.

Suresh, Babar e Raj (1996) introduziram uma nova abordagem para classificar os eventos básicos, dependendo, da sua contribuição para a probabilidade do evento topo de falha e a sua contribuição para a incerteza do evento topo, com base na teoria dos conjuntos *fuzzy*. Eles introduziram duas medidas de importância diferentes: medida de importância *fuzzy* (FIM), com base na abordagem distância euclidiana e medida de importância *fuzzy* de incerteza (FUIM). FUIM desempenha um papel

importante na redução da incerteza, identificando os componentes que têm a maior contribuição para a incerteza do evento topo. Isto ajuda a decidir quais componentes deve recolher maior número de informações de modo que o cálculo da incerteza na probabilidade de falha do sistema possa ser reduzido (SURESH; BABAR; RAJ, 1996).

3.7 ANÁLISE DE INCERTEZAS

A utilização de conceitos *fuzzy* permite a alocação de um grau de incerteza para cada valor de probabilidade, e trata diferentes aspectos de incerteza, ao mesmo tempo. Mesmo os modelos quantitativos mais sofisticados, precisos e bem construídos podem levar a resultados enganosos se as incertezas não são tratadas em um nível aceitável (TANAKA, *et al.*, 1983).

A incerteza pode variar de incerteza de modelagem, de informações incompletas e pouco confiáveis. As incertezas na probabilidade de falha de componentes do sistema ou eventos básicos podem ser propagadas para encontrar a incerteza na probabilidade total de falhas do sistema. A abordagem convencional usa a metodologia da simulação de Monte Carlo, assumindo uma distribuição de probabilidade para a falha (MISRA, 1992).

A abordagem probabilística para análise de incerteza depende, basicamente, da suposição de uma distribuição de probabilidade para a falha, o que só pode ser obtida quando uma quantidade suficiente de dados de falha está disponível. Para superar algumas dessas dificuldades, o parâmetro de entrada é tratado como um número *fuzzy* e a variabilidade é caracterizada pela função de pertinência que pode ser obtida com base na informação disponível, ou no parecer do perito. A função de pertinência de cada conjunto *fuzzy* é geralmente assumido como sendo uma função triangular ou trapezoidal e é tratada como uma distribuição de possibilidade (SURESH; BABAR; RAJ, 1996).

Suresh, P. V *et al.* (1996) apresentam uma comparação entre o método convencional de simulação de Monte Carlo e o método de medida de importância FUIM. Neste estudo foi comparada a propagação dos erros assumidos nos eventos básicos em uma árvore de falhas em que é conhecida a distribuição de probabilidade das falhas. O resultado final, considerando mais que 1.200 ensaios da simulação de

Monte Carlo, foi igual nos dois métodos, porém o tempo utilizado para o tratamento probabilístico é muito elevado, em comparação com a abordagem de conjunto *fuzzy*.

Ferdous *et al.* (2009) também apresentaram uma comparação entre a abordagem convencional e a *fuzzy* para a medição de erro propagado no evento topo. Foram controlados diferentes níveis de erros (por exemplo, 5, 10, 15 e 20%) nos dados dos eventos básicos. No caso em que foram considerados níveis maiores de erro (15 e 20%), a abordagem *fuzzy* deu melhores resultados em comparação com a abordagem probabilística, o que a torna, neste estudo, mais realista e robusta para lidar com as imprecisões dos eventos básicos.

Zonouz e Miremadi (2006) usou uma metodologia de simulação denotada de *Fuzzy-Monte Carlo* (FMCS) para lidar com incertezas. A abordagem FMCS tem duas vantagens principais em comparação com a tradicional simulação de Monte Carlo. A primeira considera a incerteza cognitiva em conjunto com a imprecisão não cognitiva. A segunda é a de ter a capacidade de modelar a situação em que os componentes podem falhar em um único ponto do tempo, bem como aqueles que podem falhar gradualmente.

3.8 APLICAÇÃO DA MEDIDA DE POSSIBILIDADE

Foi visto anteriormente que os conceitos possibilidade e probabilidades são definidos no intervalo $[0, 1]$ e ambos fornecem uma medida de incerteza, mas eles são bastante diferentes. Também foi visto que diversos estudos mostraram que a consideração da metodologia possibilística em análise de confiabilidade e segurança é natural, devido falta de informações relacionadas à falha do sistema (MAHMOOD *et al.*, 2013).

A possibilidade de falha foi utilizada pela primeira vez como um substituto para a probabilidade de falha por Tanaka *et al.* (1983). Porém, na sua definição, a possibilidade de falha depende da probabilidade de falha. Já no trabalho de Onisawa (1988) a possibilidade de falha passa a ser uma medida subjetiva não-probabilística de confiabilidade, utilizando expressões de linguagem natural, e desse modo, pode efetivamente representar as imprecisões dos fenômenos do sistema.

Singer (1990) analisou a confiabilidade de um sistema usando números *fuzzy* da forma S e Z. Ele considerou as frequências relativas dos eventos básicos como números *fuzzy* e utilizou possibilidade em vez de medida de probabilidade, mostrando que o uso possibilístico nos operadores “E” e “OU” para construir uma árvore de falhas, permite uma avaliação simples para as distribuições de possibilidade dos principais eventos.

A fim de substituir considerações de probabilidade na FTA por aquelas de possibilidade para reduzir as dificuldades que surgem a partir de informações imprecisas e insuficiente das funções de distribuição, Kim, Ju e Gens (1996) propôs dois casos de distribuição de possibilidade usando números *fuzzy*, uma possibilidade pessimista e uma otimista.

Lin e Wang (1998), e Ding e Yu (2005) utilizaram pontuação de possibilidade *fuzzy* (FPS) para reduzir a dificuldade que surge a partir de imprecisões das funções de distribuição dos eventos básicos. Em suas abordagens, eles usaram FPS para representar a ocorrência de falha dos eventos *fuzzy*. Para inserir a taxa de falha do equipamento e a pontuação de possibilidade *fuzzy* de erro humano, uma função de transformação é usada para converter pontuação de possibilidade *fuzzy* em taxa de falha *fuzzy*.

3.9 COMPARAÇÃO ENTRE FTA E FFTA

As primeiras comparações feitas entre FFTA e a FTA convencional são em relações as propriedades dominantes da FFTA. Enquanto a FTA convencional utiliza os valores exatos nas considerações probabilísticas, a FFTA utiliza variáveis linguísticas e possibilidade. A FTA convencional não trata as informações sobre as tolerâncias e variação dos valores de probabilidade e as dependências dos eventos, enquanto FFTA geralmente usa uma possibilidade triangular ou trapezoidal, e leva em conta as incertezas nos seus cálculos. Em FTA convencional, a importância do evento básico é medida com base na contribuição direta ao evento topo, enquanto no FFTA, a contribuição das incertezas também é considerada (MAHMOOD *et al.*, 2013).

Uma FFTA pode ser muito útil quando é necessário considerar uma possível falha de componentes, mesmo que nunca tenham falhado antes e não há dados

disponíveis associados, neste caso a FFTA permite através da elicitación de especialistas lidar com as variáveis linguísticas geradas por eles e modelar de forma mais segura as possíveis falhas (MISRA; WEBER, 1989).

Além disso, FTA não é adequada quando os dados disponíveis são insuficientes para inferências estatísticas. Neste caso, a metodologia *fuzzy* pode ser o único recurso quando existe pouca informação quantitativa disponível sobre a variação dos parâmetros.

A experiência de especialistas da área fornece um banco de dados eficaz para apoiar a estimativa dos dados necessários, embora tenham de enfrentar as inúmeras avaliações conflitantes. A gestão do grande número de atributos tangíveis e intangíveis que devem ser tidos em conta representa a principal complexidade do problema. A aplicação da teoria dos conjuntos *fuzzy* torna possível aplicar o conhecimento de especialista, que muitas vezes pode ser dado como variáveis linguísticas (DESHPANDE, 2011).

Esta análise indica a eficácia da FFTA em comparação com FTA convencional, quando existe uma quantidade insuficiente de informações precisas para orientar a confiabilidade. O método proposto melhora a análise do sistema e a capacidade de julgamento do modelo de falha, e aumenta a correção da decisão do componente falha (MAHMOOD *et al.*, 2013).

4 MATERIAL E MÉTODOS

4.1 MATERIAL

O material utilizado para o desenvolvimento do método proposto neste trabalho, foram obtidos através de medições realizadas por instrumentos de monitoramento do bloco-chave de contraforte denominado D38, da barragem de concreto da Usina Hidrelétrica de Itaipu. A quantidade e quais os instrumentos utilizados são definidos a partir da análise qualitativa aplicada na árvore de falhas, construída por especialistas em segurança de barragens, do bloco D38. Ainda, através de estudos técnico-científicos, são determinadas as medidas de temperatura ambiente como sendo o principal fenômeno externo que influencia as mudanças ocorridas nas medidas dos instrumentos.

O bloco D38 foi escolhido para o desenvolvimento da metodologia deste trabalho, devido aos fatos de ser:

- (i) ser um dos blocos-chave da barragem de Itaipu, e assim, possuir um sistema de instrumentação mais completo;
- (ii) ser um bloco de contraforte, que possui a característica de ser mais esbelto que os blocos maciços, o tornando mais deformável e suscetível às influências térmicas, característica importante para o desenvolvimento da classificação *fuzzy* proposta neste trabalho;
- (iii) por já possuir uma árvore de falhas construída por engenheiros e consultores que trabalham na segurança da barragem de Itaipu (ANEXO 1), onde, várias análises já feitas através desta árvore de falhas apresentaram resultados qualitativos consistentes, validando a sua eficiência no estudo de confiabilidade do bloco D38;
- (iv) os eventos básicos dessa árvore de falhas são formados por conjuntos de medidas gerados por instrumentos de monitoramento, ou seja, séries temporais que viabilizam a aplicação de conceitos matemáticos e estatísticos para o tratamento dos dados e obtenção de resultados.

Desse modo, o trabalho apresentado é desenvolvido sobre as medidas de sete instrumentos de monitoramento instalados na estrutura e fundação do bloco D38 (FIGURA 4.1): Piezômetro PS-D-85; Piezômetro PS-D-86; Piezômetro PS-D-87; Extensômetro EM-D-13; Pêndulo Invertido PI-D-38X; Pêndulo Invertido PI-D-38Y; Medidor de Vazão MV-D-03 (não representado na figura) e as medidas de Temperatura Ambiente (T) ocorridas na barragem.




FIGURA 4.1 – Instrumentos do Bloco D38.
FONTE: Acervo de Itaipu (2009).

As características dos dados (medidas dos sete instrumentos e as medidas de temperatura ambiente) fornecidos pela Itaipu Binacional, estão descritas nos QUADRO 4 e QUADRO 5.

Instrumento	Piezômetro PS-D-85	Piezômetro PS-D-86	Piezômetro PS-D-87	Extensômetro EM-D-13
Quantidade de Medidas	1911	1911	1913	861
Unidade	msnm (metros sobre o nível do mar)	msnm	msnm	mm (milímetros)
Valor Mínimo	173,37	171,85	172,25	-0,12
Valor Máximo	216,45	194,17	217,43	0,14
Média	189,31	182,53	197,83	-0,012
Desvio-Padrão	7,29	4,33	9,74	0,0336
Data da Primeira Medida	08/02/1980	06/02/1980	01/02/1980	10/09/1980
Data da Última Medida	06/05/2014	06/05/2014	06/05/2014	15/04/2014
Intervalo entre as Medidas	Horas, Dias ou Semanas	Horas, Dias ou Semanas	Horas, Dias ou Semanas	Horas, Dias ou Semanas

QUADRO 4 – Características dos dados fornecidos pela Itaipu Binacional

FONTE: O autor

Instrumento	Medidor de Vazão MV-D-03	Pêndulo Invertido PI-D-38X	Pêndulo Invertido PI-D-38Y	Temperatura Ambiente
Quantidade de Medidas	576	758	758	861
Unidade	l/s (litros por segundo)	mm (milímetros)	mm (milímetros)	°C (graus celsius)
Valor Mínimo	0	-0,2	-1	4,3
Valor Máximo	10,71	0,9	0,1	35,4
Média	0,603	0,186	-0,39	22,18
Desvio-Padrão	1,661	0,185	0,223	4,715
Data da Primeira Medida	12/01/2004	28/01/1980	28/01/1980	01/01/1980
Data da Última Medida	05/05/2014	14/04/2014	14/04/2014	31/05/2015
Intervalo entre as Medidas	Horas, Dias ou Semanas	Horas, Dias ou Semanas	Horas, Dias ou Semanas	Dias

QUADRO 5 – Características dos dados fornecidos pela Itaipu Binacional

FONTE: O autor

Em geral, os dados utilizados foram obtidos através de leituras manuais realizadas pela equipe de técnicos de segurança de barragens da Itaipu Binacional. A frequência de leitura desses instrumentos tiveram modificações conforme as fases de solicitação das estruturas, dessa maneira, no período de enchimento do reservatório a frequência foi maior do que no período de operação. Mesmo após a etapa de

enchimento do reservatório alguns instrumentos, dependendo da importância e da zona monitorada, tiveram modificações na frequência de leituras, variando de uma leitura a cada trinta minutos a leituras a cada quinze dias.

Sobre as características específicas de cada instrumento pode-se destacar que os piezômetros utilizados (PS-D-85, 86 e 87) se encontram instalados próximos a superfície do maciço de fundação, na interface concreto-rocha (ver FIGURA 4.1). O extensômetro EM-D-13 monitora a região de montante da cortina de injeção acima do contato litológico E/D e abaixo da junta D, medindo o deslocamento das camadas da fundação com relação à base da estrutura. O medidor de vazão MV-D-03 mede a vazão infiltrada por toda a fundação e concreto no trecho entre os blocos D33 e D53. Os pêndulos invertidos permitem verificar os deslocamentos horizontal da estrutura em relação a pontos interiores do maciço rochoso que podem ser considerados fixos, esses movimentos monitorados são na direção do fluxo (PI-D-38X) e na direção das ombreiras (PI-D-38Y).

O software MATLAB R2013A é utilizado para a implementação computacional da metodologia proposta. MATLAB é uma abreviação para MATrix LABoratory e trata-se de um ambiente de alto nível que possui ferramentas avançadas de análise e visualização de dados, além de possuir características de linguagem de programação (MATSUMOTO, 2013).

Mas um dos principais motivos para a escolha do MATLAB R2013A, é o fato de funções matemáticas já conhecidas estarem programadas e agrupadas de acordo com a área de interesse em toolboxes, em especial para este trabalho, o pacote *Fuzzy Logic Toolbox* que permite a utilização de conceitos da teoria fuzzy de forma direta e simples.

4.2 METODOLOGIA

O método proposto tem como principal contribuição a abordagem neuro/fuzzy/bayesiana para a detecção automática de pontos de mudança em séries temporais geradas por instrumentos de monitoramento de barragem e um critério de classificação de nível de falha baseada na experiência de especialistas envolvidos na área de segurança de barragem modelada através de um sistema de controle *fuzzy*.

O método proposto é dividido em nove passos (FIGURA 4.2) descritos a seguir:

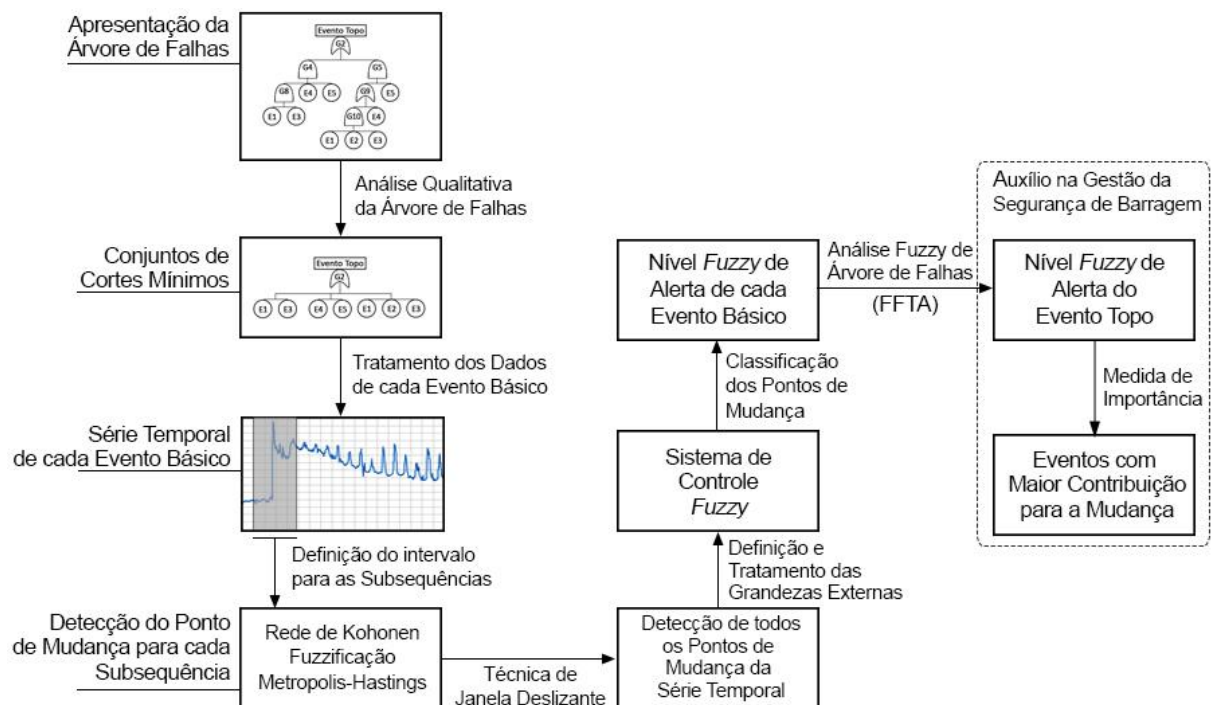


FIGURA 4.2 – Fluxograma da metodologia proposta.

FONTE: O autor

- (1) Apresentação de uma árvore de falhas desenvolvida por especialistas;
- (2) Análise qualitativa da árvore de falhas via conjunto de cortes mínimos;
- (3) Tratamento dos dados relacionados aos eventos básicos definidos pelo conjunto de cortes mínimos;
- (4) Abordagem neuro/fuzzy/bayesiana para a detecção de pontos de mudança em uma subseqüência das séries temporais;
- (5) Aplicação da técnica de janela deslizante para a obtenção de todos os pontos de mudança da série temporal;

- (6) Desenvolvimento de um sistema *fuzzy* para a classificação do nível de falha de cada ponto de mudança detectado;
- (7) Cálculo da possibilidade *fuzzy* de falha de cada evento básico;
- (8) Análise *fuzzy* de árvore de falha, determinando a possibilidade de falha do evento topo;
- (9) Determinação do evento com maior contribuição para a falha do evento topo através de medida de importância.

Os dados utilizados no desenvolvimento do método foram concedidos pela equipe de engenharia da Usina Hidrelétrica de Itaipu, responsável pela segurança de sua barragem.

4.2.1 Árvore de Falhas do Bloco D38 da Barragem de Itaipu

A árvore de falha do bloco-chave D38, desenvolvida por especialista em segurança de barragem e utilizada pela equipe responsável pela segurança da barragem de Itaipu, é apresentada no ANEXO 1. Não é objetivo deste trabalho explicar o desenvolvimento dessa árvore de falhas, apenas aceitar o seu diagrama para a aplicação do método proposto.

Essa árvore de falhas foi desenvolvida para modelar a possibilidade do bloco D38 sofrer os fenômenos descritos na Seção 2.1, de tombamento ou deslizamento. A partir do evento topo definido, o restante do diagrama da árvore de falhas foi descrito através de portas lógicas “E” e “OU” até a obtenção de eventos básicos sendo representados por instrumentos de monitoramento.

A partir da árvore de falha do bloco D38 apresentada, são aplicados os elementos padrões definidos na Seção 2.9.2 para gerar o diagrama dado pela FIGURA 4.3,

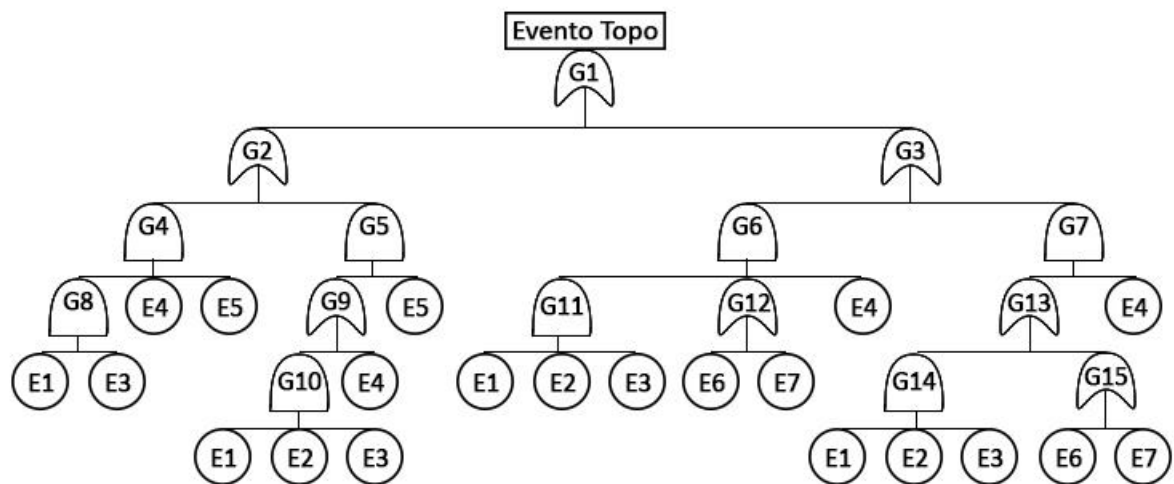


FIGURA 4.3 - Árvore de Falhas do Bloco D38 da barragem de Itaipu.
FONTE: O autor

onde as portas lógicas da árvore de falhas carregam informações lógicas já apresentadas no texto e também podem representar alguns eventos físicos. Assim, tem-se as seguintes descrições:

- G1: Porta Lógica “OU” / Evento Topo (Falha do Sistema);
- G2: Porta Lógica “OU” / Risco de Tombamento;
- G3: Porta Lógica “OU” / Risco de Deslizamento;
- G4: Porta Lógica “E”;
- G5: Porta Lógica “E”;
- G6: Porta Lógica “E”;
- G7: Porta Lógica “E”;
- G8: Porta Lógica “E” / Aumento de subpressões a montante;
- G9: Porta Lógica “OU”;
- G10: Porta Lógica “E” / Aumento de subpressões a montante;
- G11: Porta Lógica “E” / Aumento de subpressões a montante;
- G12: Porta Lógica “OU” / Aumento no deslocamento horizontal da base;
- G13: Porta Lógica “OU”;
- G14: Porta Lógica “E” / Aumento de subpressões a montante;
- G15: Porta Lógica “OU” / Aumento no deslocamento horizontal da base.

Todos os eventos básicos são representados por instrumentos de monitoramento do bloco D38, que geram dados para a análise dos eventos físicos descritos anteriormente.

- E1: Piezômetro (PS-D-85);
- E2: Piezômetro (PS-D-86);
- E3: Piezômetro (PS-D-87);
- E4: Extensômetro (EM-D-13) / Distensão da fundação a montante;
- E5: Medidor de Vazão (MV-D-03) / Aumento de vazão;
- E6: Pêndulo Invertido (PI-D-38X);
- E7: Pendulo Invertido (PI-D-38Y).

Atualmente, Itaipu utiliza as árvores de falhas apenas como um modelo qualitativo, onde as informações de critérios de alertas gerados por eventos básicos são transmitidos através do diagrama da árvore de falhas para o evento topo. O objetivo do método proposto neste texto, é modelar através da teoria *fuzzy* os conceitos qualitativos utilizados pelos responsáveis na análise da árvore de falhas, gerando resultados quantitativos mais informativos.

4.2.2 Análise Qualitativa da Árvore de Falhas

Esta etapa do método consiste em uma análise qualitativa da árvore de falha, feita através da técnica de Cortes Mínimos apresentada na SEÇÃO 2.8.4. Esse tratamento permite uma organização dos eventos, determinando quais os eventos básicos que devem ser investigados com maior atenção.

A técnica para determinar o conjunto de cortes mínimos de uma árvore de falha, consiste em aplicar conceitos da álgebra booleana dados no QUADRO 1, para transformar seu formato gráfico da FIGURA 4.3 em uma equação, ou seja,

$$\begin{aligned}
 T &= G1 \\
 &= G2 + G3 \\
 &= (G4 + G5) + (G6 + G7)
 \end{aligned}$$

$$\begin{aligned}
&= (G8.E4.E5 + G9.E5) + (G11.G12.E4 + G13.E4) \\
&= (E1.E3.E4.E5 + (G10 + E4).E5) + (E1.E2.E3.(E6 + E7).E4 + \\
&\quad (G14 + G15).E4) \\
&= (E1.E3.E4.E5 + (E1.E2.E3 + E4).E5) + (E1.E2.E3.(E6 + E7).E4 + \\
&\quad (E1.E2.E3 + (E6 + E7)).E4) \\
&= E1.E3.E4.E5 + E1.E2.E3.E5 + E4.E5 + E1.E2.E3.E4.E6 + \\
&\quad E1.E2.E3.E4.E7 + E1.E2.E3.E4 + E4.E6 + E4.E7.
\end{aligned}$$

Aplicando as leis da álgebra booleana descritas no QUADRO 2, tem-se

$$\begin{aligned}
T &= (E1.E3.E4.E5 + (E1.E2.E3 + E4).E5) + (E1.E2.E3.(E6 + E7).E4 + \\
&\quad (E1.E2.E3 + (E6 + E7)).E4) \\
&= E1.E3.E4.E5 + E1.E2.E3.E5 + E4.E5 + E1.E2.E3.E4.E6 + \\
&\quad E1.E2.E3.E4.E7 + E1.E2.E3.E4 + E4.E6 + E4.E7.
\end{aligned}$$

Utilizando a lei da absorção também descrita no QUADRO 2, tem-se a seguinte expressão

$$T = E4.E5 + E4.E6 + E4.E7 + E1.E2.E3.E4. \quad (50)$$

A Equação 50 representa o conjunto de cortes mínimos da árvore de falhas.

Utilizando os conectivos linguísticos “E” e “OU”, a Equação 50 é interpretada por: “Ocorre falha no evento topo se ocorrer falhas nos eventos E4 e E5 ou ocorrer falhas nos eventos E4 e E6 ou ocorrer falhas nos eventos E4 e E7 ou ocorrer falhas nos eventos E1, E2, E3 e E4”.

Tendo os conjuntos de cortes mínimos bem definidos, inicia-se o tratamento dos dados relacionados aos eventos básicos pertencentes a estes conjuntos.

4.2.3 Tratamento dos Dados

De acordo com a etapa anterior, os dados de sete instrumentos de monitoramento (três piezômetros, dois pêndulos invertidos, um extensômetro e um medidor de vazão) são responsáveis pela análise de possibilidade de tombamento ou deslizamento da barragem de Itaipu. Ocorre que o banco de dados com as medidas aferidas pelos instrumentos, fornecido pela Itaipu, tem medições efetuadas em datas e periodicidades diferentes, e para a metodologia proposta neste trabalho, este fato deve ser contornado, ou seja, em cada data escolhida para análise, cada um dos instrumentos tem que ter sua medida definida.

Para isso, foi desenvolvida uma rotina computacional por meio do *software* MATLAB R2013A, visando o tratamento destes dados. Para cada um dos instrumentos o algoritmo segue os três seguintes passos:

Passo 01: Para os dias em que ocorreram medidas, gerar uma única medida através da média de todas as medidas aferidas no dia;

Passo 02: Gerar medidas para os dias em que não ocorreram medições, através de interpolação linear (RUGGIERO; LOPES, 1996), desse modo, todos os dias entre a primeira e a última medição passam a ter uma única medida;

Passo 03: O intervalo de tempo escolhido para este trabalho é de sete em sete dias, ou seja, semanal. Assim, foi escolhida um mesmo dia comum a todos os instrumentos e a partir dessa data foi calculado a média com as medidas dos próximos sete dias, assim por diante até os últimos sete dias. A escolha para a utilização de médias semanais é justificada pelo fato dos instrumentos apresentarem pequenas variações de um dia para o outro, ou seja, variações consideradas “lentas”.

O programa desenvolvido no MATLAB R2013A com esses três passos descritos acima, está apresentado no APÊNDICE 1.

A partir do tratamento dos dados, obtém-se sete séries temporais, com valores apresentados em intervalos periódicos de sete dias, e nos mesmos dias, permitindo uma análise do bloco-chave D38 para cada semana.

4.2.4 Detecção de Ponto de Mudança em Série Temporal

A análise de uma árvore de falha depende fortemente do que vem a ser uma falha em cada evento básico do conjunto de cortes mínimos. Porém, em sistemas em que uma falha pode gerar problemas irreversíveis, a ocorrência de uma falha é quase nula. Desse modo, a quantidade de dados que podem auxiliar no entendimento de uma falha é quase sempre insuficiente. Mesmo assim, existe um monitoramento dos dados gerados pelos eventos básicos, e o que vem a ser observado são os pontos de mudança que ocorrem nas séries temporais. Muitas vezes, essas observações podem ser feitas por especialistas capazes de interpretar essas mudanças, classificando, muitas vezes de forma subjetiva, o grau de uma possível falha. Desse modo, o acompanhamento deve ser rotineiro e a experiência do especialista é um ponto fundamental dessa análise.

A quarta etapa da metodologia consiste em detectar pontos de mudança em séries temporais de forma automática. A técnica que será utilizada para essa detecção é baseada na abordagem neuro/fuzzy/bayesiana (D'ANGELO, 2010) e (MOREIRA, 2011).

O método possui três passos: (1) clusterização dos dados da série temporal através de um mapa auto-organizável de Kohonen; (2) construção de uma nova série temporal por meio de uma fuzzificação da série temporal inicial; (3) aplicação de uma simulação Monte Carlo via algoritmo Metropolis-Hastings para a determinação do ponto de mudança. Estes três passos são ilustrados na FIGURA 4.4 e detalhados matematicamente em seguida.

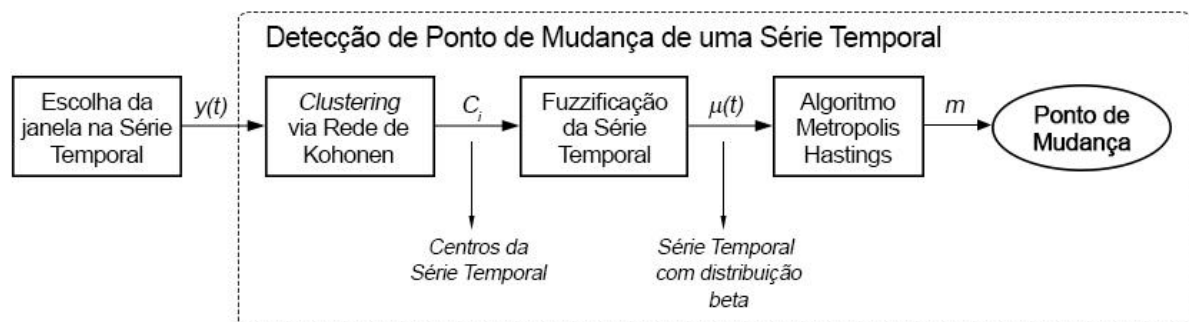


FIGURA 4.4 - Passos da metodologia para a detecção de ponto de mudança em série temporal
 FONTE: O autor

Passo 01: Clusterização via Rede de Kohonen.

A clusterização dos dados é baseada em um algoritmo de RNA auto-organizada de Kohonen. A escolha da clusterização via Rede de Kohonen é dada pelo fato de que este método permite um agrupamento adaptativo, isto é, que determina, além dos centros, uma quantidade adequada de grupos, eliminando grupos desnecessários. Este possibilita a identificação se houve ou não a ocorrência de mudança na série temporal.

A rede de Kohonen é desenvolvida a partir do algoritmo descrito na Seção 2.5. Como neste estudo tem-se interesse em apenas séries temporais de uma única dimensão, utiliza-se para esta rede somente entradas de uma única variável, que são as medidas geradas pelo instrumento de monitoramento de barragem. Como o objetivo é identificar apenas uma mudança na série temporal, a rede é inicializada com apenas dois neurônios, cujo os pesos iniciais são definidos por: valor mínimo da série temporal (w_1) e metade da subtração entre três vezes o valor mínimo e o valor máximo da série temporal (w_2). Esta escolha garante que o segundo neurônio somente tenha alguma associação com os dados se, de fato, ocorreu alguma mudança de comportamento na série temporal, isto é o que possibilita o método afirmar se houve ou não ocorrência de mudança.

Ainda no início do processo é definido um limite máximo de 1.000 iterações, uma taxa de aprendizagem $\alpha = 0,1$ para a primeira etapa do método e raio de vizinhança igual a 1. Como apenas um único neurônio vencedor de cada iteração é ajustado, não é necessário a atualização do raio de vizinhança.

A segunda parte do algoritmo consiste em um treinamento não supervisionado e competitivo da rede neural (KOHONEN, 1990). Assim, para cada iteração (i), os valores da série temporal são percorridos, calculando-se para cada valor, as distâncias euclidiana entre o valor e cada um dos neurônios. O neurônio que obtém a menor distância é considerado o vencedor e apenas o peso deste neurônio é ajustado através da equação descrita no passo 2.1.3 do algoritmo da Seção 2.5. Em seguida, a taxa de aprendizagem α é atualizada de forma linear pela equação $\alpha = 0,1 - (9 \times 10^{-5})i$. Este processo é repetido até finalizar a quantidade escolhida de iterações.

Por fim, o algoritmo utiliza um processo de eliminação por critérios de baixo desempenho, assim, é definido um índice de desempenho que quantifica o número de associações que cada neurônio tem com as entradas. Se um dos neurônios não

tem associação, ou seja, o índice de desempenho é nulo, o algoritmo indica que a série temporal não teve mudança de comportamento. Caso contrário, os pesos dos dois neurônios são definidos como os centros dos *clusters* para serem utilizados na próxima etapa do método.

Sendo assim, este primeiro passo da metodologia de detecção de ponto de mudança, dada pelo algoritmo de clusterização dos dados via rede do Kohonen, possibilita a detecção da existência ou não de um ponto de mudança na série temporal. Caso seja confirmada a existência de uma mudança, é determinado os centros da clusterização e as próximas etapas são desenvolvidas para indicar o momento em que ocorreu esta mudança.

O algoritmo para rede de Kohonen foi programado em MATLAB R2013A seguindo os passos apresentado na Seção 2.5 e encontra-se no APÊNDICE 2.

Passo 02: Fuzzificação da Série Temporal.

Os métodos clássicos de agrupamentos separam os dados em categorias, entretanto, em muitos casos, alguns elementos não podem pertencer a uma categoria específica, pois pertencem a duas ou mais categorias simultaneamente. A utilização de conjuntos *fuzzy* como métodos de agrupamentos é uma maneira eficiente de resolver tal problema, pois assim, um elemento pode pertencer a mais de uma categoria simultaneamente (PEDRYCZ, 1985).

Para este trabalho, utiliza-se um método de agrupamento *fuzzy* para gerar uma nova série temporal baseada nos centros de *clusters* calculados pela rede de Kohonen desenvolvida na etapa anterior.

Desta maneira, dada uma série temporal $y(t)$ com n pontos, os centros de *clusters* encontrados anteriormente são os valores C_1 e C_2 que dá o seguinte problema de minimização

$$\min \sum_{i=1}^2 \sum_{t=1}^n \|y(t) - C_i\|^2. \quad (51)$$

Assim, a função definida por

$$\mu(t) = \left[\sum_{j=1}^2 \frac{\|y(t) - C_1\|^2}{\|y(t) - C_j\|^2} \right]^{-1}, \quad (52)$$

tem sua imagem contida no intervalo $[0,1]$ e, desse modo, pode-se considerar $\mu(t)$ um conjunto *fuzzy* que descreve o grau de pertinência do ponto $y(t)$ em relação *cluster* de centro C_1 .

Usando testes estatísticos (D'ANGELO *et al.*, 2011b), conclui-se que a função $\mu(t)$ pode ser aproximada por uma função de distribuição beta com diferentes parâmetros de entrada, ou seja, uma distribuição $beta(a,b)$ para $t \leq m$ e uma distribuição $beta(c,d)$ para $t > m$, ou seja, a distribuição de probabilidade das variáveis $\mu(t)$ depende de cinco parâmetros (a, b, c, d, m) e tem aproximação dada por

$$f(\mu|a, b, c, d, m) \sim \prod_{i=1}^m \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \mu(i)^{a-1} (1-\mu(i))^{b-1} \prod_{i=m+1}^n \frac{\Gamma(c+d)}{\Gamma(c)\Gamma(d)} \mu(i)^{c-1} (1-\mu(i))^{d-1}, \quad (53)$$

sendo $\Gamma(x) = \int_0^\infty u^{x-1} e^{-u} du$ a função gama.

Portanto, esta etapa da metodologia proposta, através do conjunto *fuzzy* (Equação 52), transforma um conjunto de dados de uma série temporal sem qualquer conhecimento *a priori*, em uma série temporal com informações estatísticas suficientes para a aplicação de métodos de inferência bayesiana, possibilitando estimar os parâmetros da distribuição beta (Equação 53). Em especial, o parâmetro m , que é o instante em que ocorre a mudança de comportamento da série temporal $y(t)$.

O algoritmo para fuzzificação de uma série temporal está programado em MATLAB R2013A e encontra-se no APÊNDICE 3.

Na última etapa para a detecção do ponto de mudança, será utilizada uma formulação bayesiana via algoritmo de Metropolis-Hastings.

Passo 03: Formulação do Algoritmo Metropolis-Hastings.

Uma vez que as etapas anteriores transformam a série original, com uma distribuição de probabilidade qualquer, em uma nova série temporal $\mu(t)$ com uma função de distribuição de probabilidade beta, então, o novo modelo estatístico fixado é considerado em uma formulação bayesiana para estimar os parâmetros da distribuição beta que se aproxima da nova série temporal, e com isso, estima-se o parâmetro m (D'ANGELO *et al.*, 2011b). Nesta etapa, o algoritmo de Metropolis-Hastings (Seção 2.8.4) é utilizado para efetuar a simulação Monte Carlo via cadeia de Markov, com o fim de estimar os parâmetros.

Em termos práticos, o algoritmo Metropolis-Hastings é especificado sobre o fato de que nas etapas anteriores a série temporal transformada $\mu(t)$ segue as seguintes distribuições: $\mu(t) \sim \text{beta}(a, b)$ para $t = 1, \dots, m$ e $\mu(t) \sim \text{beta}(c, d)$ para $t = m + 1, \dots, n$. Assim, os parâmetros que devem ser estimados pelo algoritmo são a, b, c, d e o ponto de mudança m .

Como os valores a, b, c e d devem ser parâmetros de uma distribuição beta, então, devem ser números reais positivos, assim, utiliza-se como distribuição proposta $q(\cdot)$ para gerar candidatos a estes parâmetros, a distribuição *Gama*(0,1, 0,1). No caso do valor m , que deve pertencer ao conjunto discreto $\{1, 2, \dots, n\}$, a distribuição proposta $q(\cdot)$ para gerar candidatos ao valor m , é dada pela distribuição uniforme $U\{1, 2, \dots, n\}$. Deste modo, um vetor $\theta' = (a', b', c', d', m')$ gerado pela distribuição proposta $q(\cdot)$ tem $a', b', c', d' \sim \text{Gama}(0,1, 0,1)$ e $m' \sim U\{1, 2, \dots, n\}$.

Para a distribuição de interesse $\pi(\theta)$, é adotada a distribuição *a posteriori* de θ , determinada pela série temporal $\mu(t)$, isto é, $p(\mu|\theta)$. Assim, a função de verossimilhança $l(\mu; \theta)$ é dada pela função $f(\mu|a, b, c, d, m)$ da Equação 53, e as distribuições *a priori* de $\theta = (a, b, c, d, m)$, é a distribuição *Gama*(0,1, 0,1) para os parâmetros a, b, c e d e $U\{1, 2, \dots, n\}$ para o parâmetro m . Logo, as probabilidades são calculadas por

$$p(x) = \frac{0,1^{0,1} x^{0,1-1} e^{-0,1x}}{\Gamma(0,1)}, \quad (54)$$

para $x = a, b, c$ ou d e

$$p(m) = \frac{1}{n}. \quad (55)$$

Desta forma, se a cadeia está no estado $\theta_i = (a_i, b_i, c_i, d_i, m_i)$, a probabilidade de aceitação (Equação 33) para cada parâmetro do novo valor $\theta' = (a', b', c', d', m')$ gerado por $q(\cdot)$, é calculada por:

1. Parâmetro a :

$$\begin{aligned} \alpha(a_i, a') &= \min \left(1, \frac{l(a', b_i, c_i, d_i, m_i; \mu) \cdot p(a') \cdot q(a_i | a')}{l(a_i, b_i, c_i, d_i, m_i; \mu) \cdot p(a_i) \cdot q(a' | a_i)} \right) \\ &= \min \left(1, \frac{f(\mu | a', b_i, c_i, d_i, m_i) \cdot p(a') \cdot p(a') p(b_i) p(d_i) p(m_i)}{f(\mu | a_i, b_i, c_i, d_i, m_i) \cdot p(a_i) \cdot p(b_i) p(c_i) p(d_i) p(m_i)} \right) \\ &= \min \left(1, \frac{\prod_{j=1}^{m_i} \frac{\Gamma(a' + b_i)}{\Gamma(a') \Gamma(b_i)} \mu(j)^{a'-1} (1 - \mu(j))^{b_i-1}}{\prod_{j=1}^{m_i} \frac{\Gamma(a_i + b_i)}{\Gamma(a_i) \Gamma(b_i)} \mu(j)^{a_i-1} (1 - \mu(j))^{b_i-1}} \right. \\ &\quad \cdot \frac{\prod_{j=m_i+1}^n \frac{\Gamma(c_i + d_i)}{\Gamma(c_i) \Gamma(d_i)} \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1} \cdot \frac{p(a')^2}{p(a_i)^2}}{\prod_{j=m_i+1}^n \frac{\Gamma(c_i + d_i)}{\Gamma(c_i) \Gamma(d_i)} \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1} \cdot \frac{p(a_i)^2}{p(a_i)^2}} \left. \right) \\ &= \min \left(1, \frac{\prod_{j=1}^{m_i} \frac{\Gamma(a' + b_i)}{\Gamma(a') \Gamma(b_i)} \mu(j)^{a'-1}}{\prod_{j=1}^{m_i} \frac{\Gamma(a_i + b_i)}{\Gamma(a_i) \Gamma(b_i)} \mu(j)^{a_i-1}} \cdot \left(\frac{0,1^{0,1} a'^{0,1-1} e^{-0,1 a'} \Gamma(0,1)^{-1}}{0,1^{0,1} a_i^{0,1-1} e^{-0,1 a_i} \Gamma(0,1)^{-1}} \right)^2 \right) \\ &= \min \left(1, \left(\frac{a_i}{a'} \right)^{0,9} e^{-0,1(a'-a_i)} \right)^2 \cdot \left[\frac{\Gamma(a' + b_i) \Gamma(a_i)}{\Gamma(a_i + b_i) \Gamma(a')} \right]^{m_i} \cdot \prod_{j=1}^{m_i} \mu(j)^{a'-a_i}. \end{aligned}$$

Analogamente, pode-se definir as probabilidades de aceitação dos outros parâmetros.

2. Parâmetro b :

$$\alpha(b_i, b') = \min \left(1, \left(\frac{b_i}{b'} \right)^{0,9} e^{-0,1(b'-b_i)} \right)^2 \cdot \left[\frac{\Gamma(a_i + b') \Gamma(b_i)}{\Gamma(a_i + b_i) \Gamma(b')} \right]^{m_i} \cdot \prod_{j=1}^{m_i} (1 - \mu(j))^{b'-b_i}.$$

3. Parâmetro c :

$$\alpha(c_i, c') = \min \left(1, \left(\left[\frac{c_i}{c'} \right]^{0,9} e^{-0,1(c'-c_i)} \right)^2 \cdot \left[\frac{\Gamma(c' + d_i) \Gamma(c_i)}{\Gamma(c_i + d_i) \Gamma(c')} \right]^{m_i} \cdot \prod_{j=m_i+1}^n \mu(j)^{c'-c_i} \right).$$

4. Parâmetro d :

$$\alpha(d_i, d') = \min \left(1, \left(\left[\frac{d_i}{d'} \right]^{0,9} e^{-0,1(d'-d_i)} \right)^2 \cdot \left[\frac{\Gamma(c_i + d') \Gamma(d_i)}{\Gamma(c_i + d_i) \Gamma(d')} \right]^{m_i} \cdot \prod_{j=m_i+1}^n (1 - \mu(j))^{d'-d_i} \right).$$

5. Parâmetro m (lembrando-se que $m \sim U\{1, 2, \dots, n\}$):

$$\begin{aligned} \alpha(m_i, m') &= \min \left(1, \frac{l(a_i, b_i, c_i, d_i, m'; \mu) \cdot p(m') \cdot q(m_i | m')}{l(a_i, b_i, c_i, d_i, m_i; \mu) \cdot p(m_i) \cdot q(m' | m_i)} \right) \\ &= \min \left(1, \frac{f(\mu | a_i, b_i, c_i, d_i, m') \cdot p(m') \cdot p(a_i) p(b_i) p(d_i) p(m')}{f(\mu | a_i, b_i, c_i, d_i, m_i) \cdot p(m_i) \cdot p(b_i) p(c_i) p(d_i) p(m_i)} \right) \\ &= \min \left(1, \frac{f(\mu | a_i, b_i, c_i, d_i, m')}{f(\mu | a_i, b_i, c_i, d_i, m_i)} \cdot \frac{(1/n)^2}{(1/n)^2} \right) \\ &= \min \left(1, \left[\frac{\Gamma(a_i + b_i)}{\Gamma(a_i) \Gamma(b_i)} \right]^{m'-m_i} \left[\frac{\Gamma(c_i + d_i)}{\Gamma(c_i) \Gamma(d_i)} \right]^{m_i-m'} \right. \\ &\quad \cdot \frac{\prod_{j=1}^{m'} \mu(j)^{a_i-1} (1 - \mu(j))^{b_i-1}}{\prod_{j=1}^{m_i} \mu(j)^{a_i-1} (1 - \mu(j))^{b_i-1}} \cdot \frac{\prod_{j=m'+1}^n \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1}}{\prod_{j=m_i+1}^n \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1}} \left. \right). \end{aligned}$$

Após o cálculo das probabilidades de aceitação de cada parâmetro, um valor u é sorteado a partir da distribuição $U(0,1)$, e cada parâmetro do novo vetor $\theta_{i+1} = (a_{i+1}, b_{i+1}, c_{i+1}, d_{i+1}, m_{i+1})$ é construído através da regra: Se $u < \alpha(x_i, x')$, então aceitar o novo valor e fazer $x_{i+1} = x'$, caso contrário, rejeitar e fazer $x_{i+1} = x_i$, com $x = a, b, c, d$ e m .

Em seguida, o valor da iteração i é ajustado para $i + 1$, um novo vetor θ' é gerado por $q(\cdot)$ e o processo é repetido. Para este trabalho, são escolhidas 1.000

iterações, que ao final geram uma cadeia de Markov com 1.000 estimativas para o vetor $\theta = (a, b, c, d, m)$.

Como o objetivo desta etapa é determinar a melhor estimativa do parâmetro m , o método é finalizado com a escolha do valor de m que ocorre com maior frequência entre as 1.000 estimativas, pois, este é o valor, entre os estimados, que tem a maior probabilidade de ser o parâmetro m da distribuição beta que aproxima-se das distribuição dos dados da série temporal $\mu(t)$, e conseqüentemente, é o instante de mudança de comportamento da série temporal $y(t)$.

O algoritmo para detecção do ponto de mudança também foi programado em MATLAB R2013A e encontra-se no APÊNDICE 4.

4.2.5 Técnica de Janela Deslizante

Uma das dificuldades da metodologia de detecção de ponto de mudança em série temporal através da abordagem neuro/fuzzy/bayesiana, é não ser eficiente em relação a séries temporais extensas, com uma quantidade elevada de valores. Assim, uma técnica interessante que contorna este problema e é utilizada neste trabalho, é a de janela deslizante, descrita na Seção 2.5.

Desse modo, o método de detecção de ponto de mudança é aplicada em uma subsequência da série temporal com apenas os 80 (oitenta) primeiros pontos, se não for encontrado nenhum ponto de mudança, a janela com a subsequência desliza, definindo uma nova subsequência novamente com 80 (oitenta) pontos, mas agora se iniciando a partir do primeiro ponto após o último da subsequência anterior. Se algum ponto da subsequência for detectado pelo método como sendo um ponto de mudança, este ponto de mudança é armazenado, e a janela com a subsequência desliza definindo uma nova subsequência novamente com 80 (oitenta) pontos, mas agora se iniciando a partir do ponto detectado. Este processo se repete até a janela com a subsequência deslizar por toda a série temporal, detectando todos os possíveis pontos de mudança.

O algoritmo para a técnica de janela deslizante para a detecção dos pontos de mudança da série temporal total está programado no *software* MATLAB R2013A e encontra-se no APÊNDICE 5.

O próximo passo da metodologia consiste em definir o quanto que um ponto de mudança detectado pode ser de fato classificado como sendo uma falha, ou melhor, classificar qual é o seu nível de falha (normal, atenção ou muita atenção).

4.2.6 Sistema de Controle *Fuzzy*

Em muitos casos, a classificação de uma anomalia encontrada em uma série temporal pode ser feita de forma intuitiva através da experiência de um analista, onde reconhece o ponto de mudança e decide, através de sua experiência e análise de outras grandezas, o nível de importância da mudança. Baseada neste tipo de análise feita pela experiência dos agentes envolvidos no monitoramento de uma barragem, é apresentado nesta etapa da metodologia um método de classificação do nível de falha através da formalização dos conceitos subjetivos utilizados pelos especialistas por meio de sistemas *fuzzy* (Seção 2.7.2).

Para cada um dos instrumentos analisado o método de classificação das mudanças de comportamento é dividido em quatro passos: (1) Definição das grandezas externas que influenciam nas variações ocorridas nas medidas do instrumento; (2) Definição dos vetores de variação; (3) Construção do sistema *fuzzy* baseado em regras definidas pela experiência de especialistas; (4) Classificação do nível de alerta para os pontos de mudança.

Passo 01: Definição das Grandezas Externas.

Todo instrumento de monitoramento da Barragem de Itaipu apresenta variações em suas medidas, que são consideradas, na maioria das vezes normais devido as variações de diversas grandezas externas a estrutura e fundação da barragem, como temperatura ambiente, temperatura da água do reservatório, nível do reservatório, nível pluviométrico, entre outros. Este passo da metodologia de

classificação consiste em determinar quais grandezas externas exercem maior influência no comportamento do instrumento.

No atual trabalho, a determinação da principal grandeza externa que influencia nas medidas dos instrumentos escolhidos foi baseada no estudo desenvolvido por Fiorini *et al.* (2001). Esse trabalho apresenta uma comparação entre o comportamento de diversos tipos de barragem de concreto de Itaipu com base na experiência dos autores maturada ao longo de 20 anos de análise e interpretação dos resultados da instrumentação das obras civis da barragem de Itaipu.

Fiorini *et al.* (2001) afirmam que em blocos de contraforte, caso do bloco D38, os efeitos variacionais encontrados nos instrumentos têm forte correlação com as variações sazonais da temperatura ambiente. No final do verão, o paramento de jusante atinge sua dilatação térmica máxima, deformando a crista da barragem para cima e para a montante. No final do inverno, ocorre o processo inverso, quando a face da jusante se contrai, por chegarem as temperaturas mínima sazonais, provocando o deslocamento da crista para baixo e para a jusante. A face de montante, por estar em contato com a água do reservatório, com nível praticamente constante e temperatura com pequenas variações, funciona de forma passiva não afetando praticamente este comportamento. Este tipo de comportamento é mais acentuado nos blocos de contraforte do que nos blocos de gravidade maciça, devido ao fato de serem mais esbeltos e portanto menos rígidos e com menor inércia térmica.

A influência da variação térmica nos blocos de contraforte fica evidente com as variações sazonais dos deslocamentos horizontais da crista da barragem com relação a base do bloco, medidas pelos pêndulos diretos e invertidos instalados no bloco.

Outras evidências da influência térmica no comportamento de blocos de contraforte se dão através do comportamento sazonal das subpressões observadas pelas variações nas medidas dos piezômetros instalados no contato concreto-rocha da barragem. As variações sazonais das subpressões são explicadas devido ao fato de que os movimentos citados anteriormente permitem que no inverno ocorra uma abertura ou descompressão do contato concreto-rocha e consequente o aumento de permeabilidade, devido a abertura de juntas, fraturas e fissuras na rocha, permitindo uma maior percolação da água do reservatório. No verão, a compressão e fechamento do contato resulta numa redução da permeabilidade da fundação sob a cabeça de montante do bloco (FIORINI *et al.*, 2001).

Outro trabalho que também analisou a influência de grandezas externas sobre a barragem de Itaipu é dado por Patias *et al.* (2015), nele é apresentado um estudo das correlações entre a variação do nível do reservatório e da temperatura ambiente com as vazões de infiltração ocorridas na barragem de Itaipu.

Segundo Patias *et al.* (2015), a variação da temperatura ambiente apresenta forte correlação negativa ($r = -0,81$) com a variação das vazões infiltradas pelo concreto, onde a redução da temperatura contribui em grande parte para o aumento das vazões infiltradas pelo concreto, análogo ao estudo citado anteriormente. Ainda, observou-se as variações do nível do reservatório e as vazões de infiltração em blocos de concreto apresentam fraca correlação ($r = -0,31$).

É importante destacar, que no trabalho de Patias *et al.* (2015) é relatado a existência de uma defasagem de 2 (dois) meses para que a temperatura ambiente exerça maior correlação sobre as medidas geradas pelos instrumentos de monitoramento da vazão de infiltração nas barragens de concreto, explicando o tempo necessário para que o concreto do bloco absorva totalmente a temperatura externa e altere sua forma geométrica devido a dilatação térmica. No presente trabalho, também são desenvolvidas análises de correlações entre a temperatura ambiente e as medidas dos instrumentos do bloco D38, determinando uma defasagem de 9 (nove) semanas (os resultados estão descritos no próximo capítulo).

Portanto, devido aos resultados dos trabalhos citados (FIORINI *et al.*, 2001) e (PATIAS *et al.*, 2015), de que o efeito da variação de temperatura entre verão e inverno provoca variações de deslocamentos horizontais e verticais, variações nas subpressões no contato concreto-rocha e variações nas vazões de infiltração, sendo mais pronunciados nos blocos de contraforte, adota-se para este trabalho a temperatura ambiente como sendo a grandeza externa que exerce influência nas variações dos instrumentos instalados no bloco de contraforte D38.

Passo 02: Vetor de Variações dos Dados.

Após a consideração da temperatura ambiente ser a grandeza externa que tem maior influência nas variações encontradas nos instrumentos de monitoramento do bloco D38, inclusive os sete instrumentos definidos como eventos básicos da árvore de falha analisada neste trabalho, é obtido, via banco de dados da Itaipu, o conjunto de dados com as médias diárias da temperatura ambiente dos termômetros instalados na Usina Hidrelétrica de Itaipu.

Os dados da temperatura também recebem o mesmo tratamento de dados descrito na Seção 4.2.3 através do algoritmo do APÊNDICE 1, onde é gerado um conjunto de dados com uma medida para cada sete dias, através da média semanal, para os mesmo dias definidos para os dados dos eventos básicos. Assim, cada semana, tem-se a medida da temperatura externa e as medidas dos instrumentos da árvore de falhas.

A fim de organizar melhor as medidas utilizadas, os dados acima são considerados como vetores, ou seja, $\vec{X} = (x_1, x_2, \dots, x_n)$, com x_i sendo a medida da variável X relativa a semana i e n sendo a quantidade total de semanas analisadas. Sendo o vetor \vec{X} um elemento do conjunto $I = \{\vec{T}, \vec{E1}, \vec{E2}, \dots, \vec{E7}\}$, onde $\vec{T} = (T_1, T_2, \dots, T_n)$ é o vetor com as medidas da temperatura ambiente, $\vec{E1} = (e1_1, e1_2, \dots, e1_n)$ é o vetor com as medidas do instrumento do evento básico E1 (Piezômetro PS-D-85), $\vec{E2} = (e2_1, e2_2, \dots, e2_n)$ é o vetor com as medidas do instrumento do evento básico E2 (Piezômetro PS-D-86) e assim por diante.

Como a intenção é relacionar a variação da temperatura com as variações das medidas dos instrumentos, é necessário a construção de vetores com as variações desses dados. Assim, para cada conjunto de dados definido pelo vetor $\vec{X} = (x_1, x_2, \dots, x_n) \in I$, define-se o vetor de variação dos dados por:

$$\vec{V}_X = (v_1, v_2, \dots, v_{n-1}), \quad (56)$$

onde $v_i = |x_{i+1} - x_i|$.

Desse modo, levando em conta a defasagem do tempo em que a temperatura exerce influência sobre as medidas dos instrumentos, é possível relacionar a variação da temperatura com a variação de cada instrumento. Essa relação é dada através da construção de um sistema *fuzzy* baseado na experiência adquirida por especialistas na área de segurança de barragem.

Passo 03: Construção do Sistema *Fuzzy*.

Muitas das mudanças ocorridas nos padrões de medidas de um instrumentos são consideradas normais devido ao fato de ter ocorrido variação na temperatura ambiente, fenômeno que altera a geometria do bloco e consequentemente, explica a

variação dada no instrumento. A analogia que relaciona a mudança de temperatura com a mudança nas medições do instrumento, pode ser realizada através de um especialista experiente, quando mudanças atípicas são facilmente detectadas. Nesse tipo de análise, termos subjetivos como “pouca variação”, “pequena alteração”, “muita atenção” são utilizadas e mesmo assim, apesar da falta de exatidão, produzem bons resultados.

Esta etapa da metodologia consiste na utilização da teoria de conjuntos *fuzzy* para modelar matematicamente os termos subjetivos utilizados pelos especialistas e construir um sistema *fuzzy* capaz de classificar o nível que se deve dar de atenção para as mudanças de comportamento detectadas.

Para isso, é construído um controlador *fuzzy* baseado no método de inferência de Mamdani (Seção 2.7.4) com o auxílio do pacote *FUZZY LOGIC TOOLBOX* do *software* MATLAB R2013A, capaz de analisar a influência que a variação de temperatura (\vec{V}_T) exerce sobre a variação das medidas de cada instrumento ($\vec{V}_{E1}, \vec{V}_{E2}, \dots, \vec{V}_{E7}$).

Com o cuidado de generalização deste estudo, é apresentado o desenvolvimento do controlador *fuzzy* que analisa a relação entre a variação de temperatura (\vec{V}_T) e a variação das medidas do instrumento E_i (\vec{V}_{Ei}), com $i \in \{1, 2, \dots, 7\}$. Assim, o desenvolvimento para os sete instrumentos segue de forma análoga.

O controlador *fuzzy* é construído através das seguintes etapas:

Etapa 1 (Fuzzificação): Neste estágio as entradas e saídas do sistema são modeladas por conjuntos *fuzzy* com seus respectivos domínios.

Para a entrada “Variação da Temperatura (V_T)” são definidos três conjuntos *fuzzy* com domínio $[0, \infty)$:

- O conjunto *fuzzy* “Baixa Variação de Temperatura”, definido pelo número *fuzzy* de forma-Z dado por

$$\widehat{B}V_T = \left(-\infty, -\infty, 0, \frac{\max(\vec{V}_T)}{2} \right), \quad (57)$$

onde $\max(\vec{V}_T)$ é o máximo valor do vetor \vec{V}_T .

- O conjunto *fuzzy* “Média Variação de Temperatura”, definido pelo número *fuzzy* triangular dado por

$$\widetilde{M}V_T = \left(0, \frac{\max(\overrightarrow{V_T})}{2}, \frac{\max(\overrightarrow{V_T})}{2}, \max(\overrightarrow{V_T})\right). \quad (58)$$

- O conjunto *fuzzy* “Alta Variação de Temperatura”, definido pelo número *fuzzy* forma-S dado por

$$\widetilde{A}V_T = \left(\frac{\max(\overrightarrow{V_T})}{2}, \max(\overrightarrow{V_T}), \infty, \infty\right). \quad (59)$$

Para a entrada “Variação da Medida do Instrumento Ei (V_{Ei})”, também são definidos três conjuntos *fuzzy* com domínio $[0, \infty)$:

- O conjunto *fuzzy* “Baixa Variação de Ei”, definido pelo número *fuzzy* de forma-Z dado por

$$\widetilde{B}V_{Ei} = \left(-\infty, -\infty, 0, \frac{\max(\overrightarrow{V_{Ei}})}{2}\right), \quad (60)$$

onde $\max(\overrightarrow{V_{Ei}})$ é o máximo valor do vetor $\overrightarrow{V_{Ei}}$.

- O conjunto *fuzzy* “Média Variação de Ei”, definido pelo número *fuzzy* triangular dado por

$$\widetilde{M}V_{Ei} = \left(0, \frac{\max(\overrightarrow{V_{Ei}})}{2}, \frac{\max(\overrightarrow{V_{Ei}})}{2}, \max(\overrightarrow{V_{Ei}})\right). \quad (61)$$

- O conjunto *fuzzy* “Alta Variação de Ei”, definido pelo número *fuzzy* forma-S dado por

$$\widetilde{A}V_{Ei} = \left(\frac{\max(\overrightarrow{V_{Ei}})}{2}, \max(\overrightarrow{V_{Ei}}), \infty, \infty\right). \quad (62)$$

A saída do sistema é denotado como sendo o “Nível de Alerta” que classifica as variações das medidas do instrumento em relação a variação de temperatura.

Desse modo, são construídos três conjuntos *fuzzy* com domínio no intervalo $[0,1]$, que modelam a possibilidade de uma variação do instrumento pertencer ou não a normalidade das suas medidas.

Assim, para a saída “Nível de Alerta (*NA*)” são definidos os três seguinte conjuntos *fuzzy*:

- O conjunto *fuzzy* “Nível de Alerta Normal”, definido pelo número *fuzzy* de forma-Z dado por

$$\tilde{N} = \left(-\infty, -\infty, 0, \frac{1}{2} \right). \quad (63)$$

- O conjunto *fuzzy* “Nível de Alerta Atenção”, definido pelo número *fuzzy* triangular dado por

$$\tilde{A} = \left(0, \frac{1}{2}, \frac{1}{2}, 1 \right). \quad (64)$$

- O conjunto *fuzzy* “Nível de Alerta Muita Atenção”, definido pelo número *fuzzy* forma-S dado por

$$\widetilde{MA} = \left(\frac{1}{2}, 1, \infty, \infty \right). \quad (65)$$

Em seguida são definidas as regras que associam as entradas com as saídas do sistema *fuzzy*.

Etapa 2 (Base de Regras): Como foi descrito na 2.7.3, este passo é considerado como um módulo que faz parte de “núcleo” do controlador *fuzzy*. Ele é composto pelas regras *fuzzy* descritas na forma linguística “Se...Então” desenvolvidas a partir de informações de especialistas. É neste ponto que as variáveis e suas classificações linguísticas são catalogadas e, em seguida, modeladas por conjuntos *fuzzy*, isto é, funções de pertinência.

As regras para relacionar as variações de temperatura e medidas do instrumento E_i com a possibilidade de nível de alerta são dadas pela forma “Se

Variação de Temperatura é v_T e Variação da Medida do Instrumento Ei é v_{ei} , então Nível de Alerta é α ”.

Através de especialistas responsáveis pela segurança da barragem de Itaipu foi definido o QUADRO 6 que apresenta todas as possibilidades de relacionar variação de temperatura com variação da medida do instrumento Ei (onde BV é baixa variação, MV é média variação, AV é alta variação, N é normal, A é atenção e MA é muita atenção) .

Temperatura \ Instrumento	BV_{Ei}	MV_{Ei}	AV_{Ei}
BV_T	N	A	MA
MV_T	N	N	MA
AV_T	A	A	MA

QUADRO 6 - Relações entre variação de temperatura e variação da medida do instrumento Ei com nível de alerta definidos por especialistas da Itaipu

FONTE: O autor

Logo, a base de regras *fuzzy* é definida pelas seguintes regras:

- R_1 : Se V_T é Baixa Variação e V_{Ei} é Baixa Variação então NA é Normal;
- R_2 : Se V_T é Baixa Variação e V_{Ei} é Média Variação então NA é Atenção;
- R_3 : Se V_T é Baixa Variação e V_{Ei} é Alta Variação então NA é Muita Atenção;
- R_4 : Se V_T é Média Variação e V_{Ei} é Baixa Variação então NA é Normal;
- R_5 : Se V_T é Média Variação e V_{Ei} é Média Variação então NA é Normal;
- R_6 : Se V_T é Média Variação e V_{Ei} é Alta Variação então NA é Muita Atenção;
- R_7 : Se V_T é Alta Variação e V_{Ei} é Baixa Variação então NA é Atenção;
- R_8 : Se V_T é Alta Variação e V_{Ei} é Média Variação então NA é Atenção;
- R_9 : Se V_T é Alta Variação e V_{Ei} é Alta Variação então NA é Muita Atenção.

Etapa 3 (Inferência *Fuzzy*): A partir da base de regras construída com termos linguísticos, é aplicado o processo de inferência *fuzzy* de Mamdani, capaz de descrever todo o conjunto de regras em um conjunto *fuzzy* responsável por representar a possibilidade da variação medida no instrumento Ei pertencer a um certo nível de alerta. Assim, para a variação de temperatura v_T e para a variação da medida do instrumento v_{ei} , as regras descritas acima determinam os conjuntos *fuzzy* de domínios $[0,1]$ dados pelas funções pertinências

$$\begin{aligned}
\mu_{R_1}(x) &= \bar{B}V_T(v_T) \wedge \bar{B}V_{Ei}(v_{ei}) \wedge \bar{N}(x); \\
\mu_{R_2}(x) &= \bar{B}V_T(v_T) \wedge \bar{M}V_{Ei}(v_{ei}) \wedge \bar{A}(x); \\
\mu_{R_3}(x) &= \bar{B}V_T(v_T) \wedge \bar{A}V_{Ei}(v_{ei}) \wedge \bar{M}A(x); \\
\mu_{R_4}(x) &= \bar{M}V_T(v_T) \wedge \bar{B}V_{Ei}(v_{ei}) \wedge \bar{N}(x); \\
\mu_{R_5}(x) &= \bar{M}V_T(v_T) \wedge \bar{M}V_{Ei}(v_{ei}) \wedge \bar{N}(x); \\
\mu_{R_6}(x) &= \bar{M}V_T(v_T) \wedge \bar{A}V_{Ei}(v_{ei}) \wedge \bar{M}A(x); \\
\mu_{R_7}(x) &= \bar{A}V_T(v_T) \wedge \bar{B}V_{Ei}(v_{ei}) \wedge \bar{A}(x); \\
\mu_{R_8}(x) &= \bar{A}V_T(v_T) \wedge \bar{M}V_{Ei}(v_{ei}) \wedge \bar{A}(x); \\
\mu_{R_9}(x) &= \bar{A}V_T(v_T) \wedge \bar{A}V_{Ei}(v_{ei}) \wedge \bar{M}A(x),
\end{aligned} \tag{66}$$

onde v_T e v_{ei} são números reais não negativos fixos e x é uma variável real pertencente ao intervalo $[0,1]$.

Por fim, a base de regra total é modelada pelo conjunto *fuzzy* definido pela função pertinência

$$\mu_S(x) = \mu_{R_1}(x) \vee \mu_{R_2}(x) \vee \dots \vee \mu_{R_9}(x). \tag{67}$$

Etapa 4 (Defuzzificação): Com o processo de inferência *fuzzy* desenvolvido na etapa anterior, o resultado obtido (Equação 67), é a função pertinência de um conjunto *fuzzy*. Esta etapa consiste em aplicar o método de defuzzificação de centro de área descrito na Seção 2.7.3, em que a equação é dada por

$$y^*(v_T, v_{ei}) = \frac{\int \mu_S(x) x \, dx}{\int \mu_S(x) \, dx}, \tag{68}$$

e determina o valor numérico que melhor representa o “Nível de Alerta” para a variação v_{ei} devido a variação v_T .

Observa-se que o conjunto *fuzzy* que representa o nível de alerta da variação da medida do instrumento em relação a variação da temperatura ambiente pode variar entre o conjunto *fuzzy* “totalmente Normal” (gráfico sendo o triângulo retângulo de vértices $(0,0)$, $(0,1)$ e $(1/2, 0)$) e ser o conjunto *fuzzy* “totalmente Muita Atenção” (gráfico sendo o triângulo retângulo de vértices $(1/2, 0)$, $(1, 0)$ e $(1, 1)$), assim,

através da Equação 68 que calcula o centro de massa desse triângulos, tem-se que os valores numéricos que quantificam o conceito de Nível de Alerta, variam entre o valor mínimo de $1/6 \approx 1,667$ (centro de massa do triângulo “Normal”) e o valor máximo de $5/6 \approx 0.833$ (centro de massa do triângulo “Muita Atenção”). Portanto, para todas as variações v_t de temperatura e v_{e1} da medida do instrumento E1, tem-se que $y^*(v_T, v_{e1}) \in [1/6, 5/6]$.

O desenvolvimento dos controladores *fuzzy* que determinam os níveis *fuzzy* de alertas para as mudanças de comportamento nos sete instrumentos (E1, E2, ..., E7), é feita de forma análoga.

4.2.7 Classificação do Nível de Alerta para os Pontos de Mudanças

Esta etapa consiste em classificar o nível de alerta de cada ponto detectado pelo método de detecção automática de mudanças de comportamento, através do controlador *fuzzy*.

A medida relativa a semana $j \in \{1, 2, \dots, n\}$ do instrumento Ei , $i \in \{1, 2, \dots, 7\}$ é denotada por ei_j . Assim, se ei_j é uma das medida do instrumento Ei detectada pela metodologia neuro/*fuzzy*/bayesiana de detecção de ponto de mudança, calcula-se a variação da medida do instrumento ocorrida na semana j , $v_{ei} = |ei_j - ei_{j-1}|$ e a variação da temperatura ambiente correlacionada com a medida ei_j , $v_T = |T_{j-d} - T_{j-1-d}|$, onde d é o tempo de N defasagem que a temperatura exerce maior influência na medida do instrumento Ei (observe-se que os valores v_T e v_{ei} utilizados, dependem fortemente do valor de ei_j). Em seguida, os valores v_t e v_{ei} são usados como entradas no controlador *fuzzy*, gerando o valor saída $y^*(v_T, v_{ei})$, que representa o “Nível de Alerta” da mudança ocorrida na semana j pelo instrumento Ei .

Devida a dependência de v_T e v_{ei} com o valor ei_j , o valor dado pela defuzzificação de centro de área $y^*(v_T, v_{ei})$ será denotado simplesmente por $\mathcal{N}(ei_j)$ e nomeado neste trabalho como nível *fuzzy* de alerta da medida ei_j .

Deste modo, todo ponto de mudança detectado, em qualquer um dos instrumentos considerados eventos básicos, são definidos níveis *fuzzy* de alerta.

Os valores que não são considerados pontos de mudanças pela metodologia neuro/fuzzy/bayesiana, são atribuídos níveis *fuzzy* de alerta com valor $1/6$, classificando este ponto como sendo uma variação “totalmente normal”, pois foi visto, que os valores de classificação variam entre $1/6$ e $5/6$.

Deste modo, todas as variações semanais de cada instrumento tem um valor definido para o nível *fuzzy* de alerta, quantificando a possibilidade da variação ser notificada como alerta.

O algoritmo, programado no MATLAB R2013A, para a classificação dos níveis *fuzzy* de alerta através da construção de um controlador *fuzzy* encontra-se no APÊNDICE 6.

4.2.8 Análise Fuzzy de Árvore de Falhas

Após a aplicação da metodologia de detecção e classificação dos pontos de mudança nos conjuntos de medidas de cada instrumento definido como evento básico da árvore de falhas, tem-se, no período de análise, que cada variação semanal destes instrumentos está quantificada numericamente pelo nível *fuzzy* de alerta.

Assim, a partir da Equação 50 em que são definidos os conjuntos de cortes mínimos é possível, por meio de uma análise quantitativa, calcular o nível *fuzzy* de alerta para o evento topo, quantificando o nível de atenção que deve ser dado a todo o bloco D38 em relação as possibilidades de ocorrências dos eventos de tombamento ou deslizamento.

Para isso, o conceito de nível *fuzzy* de alerta é aplicado na Equação 50 e os conectivos lógicos “E” e “OU” representados por “.” e “+”, respectivamente, são considerados sobre os conceitos de t-norma e t-conorma da lógica *fuzzy* (Seção 2.7.1), onde são escolhidos para este estudo os operadores usuais: mínimo (\wedge) e máximo (\vee), respectivamente. Assim, tem-se que o nível *fuzzy* do evento topo T , em relação as variações ocorridas na semana j , é dado por

$$\begin{aligned} \mathcal{N}(T_j) = & \left(\mathcal{N}(e_{4_j}) \wedge \mathcal{N}(e_{5_j}) \right) \vee \left(\mathcal{N}(e_{4_j}) \wedge \mathcal{N}(e_{6_j}) \right) \vee \left(\mathcal{N}(e_{4_j}) \wedge \mathcal{N}(e_{7_j}) \right) \\ & \vee \left(\mathcal{N}(e_{1_j}) \wedge \mathcal{N}(e_{2_j}) \wedge \mathcal{N}(e_{3_j}) \wedge \mathcal{N}(e_{4_j}) \right). \end{aligned} \quad (69)$$

Deste modo, para cada semana, é possível calcular um valor numérico que descreve o comportamento do bloco D38 em relação as variações de alguns instrumentos de monitoramento instalados na estrutura e fundação do bloco, levando em conta a influência de variações externas a barragem.

O algoritmo para a análise *fuzzy* de árvore de falhas, está programado no MATLAB R2013A e encontra-se no APÊNDICE 7.

4.2.9 Medida de Importância

De acordo com a Seção 2.9.6 uma das vantagens do estudo da confiabilidade de um sistema através de uma análise de árvore de falhas, é a possibilidade de detectar certa vulnerabilidade do sistema. Esta última etapa da metodologia proposta, é dedicada a utilizar técnicas de medidas de importância para a identificação dos eventos básicos (medidas dos instrumentos de monitoramento) que mais contribuem para a mudança no comportamento do bloco, auxiliando na gestão da segurança da barragem.

Para este estudo é utilizado uma adaptação da medida de importância de *Fussell-Vesely* (FV) (QUADRO 3), em que o valor de probabilidade (ou possibilidade) do evento topo (P_T) é substituído pelo valor de nível *fuzzy* de alerta ($\mathcal{N}(T)$), assim a fórmula é dada por

$$FV_{Ei} = \frac{\mathcal{N}(T) - \mathcal{N}(T|Ei = 1/6)}{\mathcal{N}(T)}, \quad (70)$$

onde $\mathcal{N}(T|Ei = 1/6)$ representa o cálculo do nível *fuzzy* de alerta do evento topo (Equação 69), considerando que o nível *fuzzy* de alerta do evento Ei é mínimo, isto é, $\mathcal{N}(Ei) = 1/6$.

A Equação 70 calcula a contribuição relativa do evento básico E_i para o nível *fuzzy* de alerta do evento topo T . Logo, aplicando-se a fórmula nos sete eventos básicos, tem-se que o maior valor calculado representa o evento com maior importância na contribuição do valor de nível *fuzzy* de alerta do evento topo.


Tem-se que o algoritmo com o cálculo da medida de importância está programado no *software* MATLAB R2013A e encontra-se no APÊNDICE 8.





Em seguida, é descrita a aplicação do método através de dados reais fornecidos pela Itaipu Binacional.

5 RESULTADOS

Devido as características dos dados, descritas nos QUADROS 4 e 5, em especial, as diferença encontradas nos intervalos entre as medidas de cada instrumento, é necessário uma homogeneização das medidas. Para isso, é desenvolvido o tratamento desses dados de acordo com os critérios apresentados na Seção 4.2.3, onde, para o conjunto de dados de cada evento, são calculadas a média diária dos dias com mais de uma medida, são geradas medidas através de interpolação linear para os dias que não possuem nenhuma medida e por fim, determinado um único valor para cada semana, através da média semanal dos valores de cada dia. Assim, toda semana entre a primeira medida e a última medida, tem um valor estimado definindo a medida de cada instrumento.

Os gráficos (FIGURA 5.1) ilustram as séries temporais gerada com os dados de cada evento após o tratamento dos dados, tendo ainda destacado nos gráficos, o ponto da semana de início do enchimento do lago (17/10/1982) e uma linha tracejada no dia (05/01/1997), considerada, neste trabalho, a data em que ocorre a diminuição dos efeitos causados pelo enchimento do reservatório sobre a barragem, e assim, gerando uma estabilização no comportamento das medidas aferidas pelos instrumentos. Os valores a partir dessa linhas, são utilizados como referência de comportamento “estável” do bloco.














FIGURA 5.1 - Séries Temporais após o tratamento dos dados
FONTE: O autor

É importante destacar que nos oito gráficos apresentados acima, o conjunto de pontos que determinam o dia da semana com a média semanal das medidas de cada instrumento é comum nas oito séries temporais, o que permite, através de comparações das medidas, a análise do comportamento do bloco para cada semana.

Em seguida, a metodologia de detecção de pontos de mudança em séries temporais baseada na abordagem neuro/fuzzy/bayesiana descrita na Seção 4.2.4, é aplicada junto com a técnica de janela deslizante da Seção 4.2.5 em subsequências de 100 pontos, em cada uma das séries temporais geradas pelos dados tratados dos instrumentos E1, E2, ..., E7. Assim, são definidos para esses instrumentos, os conjuntos de pontos caracterizados como mudança no comportamento momentâneo da série temporal e que posteriormente são classificados em relação ao seu nível de atenção.

A FIGURA 5.2 apresenta, no gráfico de cada série temporal, os pontos detectados pela metodologia como sendo as mudança momentâneas de comportamento da série temporal.








FIGURA 5.2 - Pontos de mudança de comportamento detectados
 FONTE: O autor

A fim de destacar uma das vantagens em utilizar um método de detecção de ponto de mudanças em séries temporais, o QUADRO 7 apresenta a relação entre o número de pontos detectados e o total de pontos da série temporal.

Instrumento	E1	E2	E3	E4	E5	E6	E7
Pontos detectados	137	147	151	202	121	333	331
Total de pontos	1786	1786	1787	1752	537	1784	1784
Porcentagem	7,67%	8,23%	8,45%	11,53%	22,53%	18,67%	18,55%

QUADRO 7 - Relação entre número de pontos detectados e o total de pontos
 FONTE: O autor

Observa-se, pelo QUADRO 7, que menos de 25% do total de pontos de cada série temporal é considerado um ponto de mudança de comportamento, isso implica que a maioria dos pontos medidos pelos instrumentos, estão próximos a um comportamento padrão de medidas realizadas em períodos relativamente próximos.

A aplicação da próxima etapa do método, consiste em determinar se os pontos detectados estão dentro de um nível aceitável de variação exercida pela variação da temperatura ambiente.

Antes da utilização da construção do sistema *fuzzy* responsável por determinar o nível de alerta para cada ponto de mudança em relação a variação da temperatura ambiente, é realizada uma análise da correlação entre as medida de alguns instrumentos e temperatura ambiente, para determinar o intervalo de tempo necessário para o bloco sofrer maior influência da variação térmica.

Segundo especialistas envolvidos na segurança da barragem de Itaipu, os instrumentos utilizados no monitoramento de fenômenos relacionados as infiltrações de água, são os que apresentam maior sensibilidade em relação a movimentos da estrutura devido ao fenômeno de dilatação térmica. Assim, neste trabalho, foi

estudada a correlação entre os dados dos piezômetros E1, E2 e E3 e a temperatura, a partir da data (05/01/1997), considerada como referência de um comportamento mais “estável” do bloco.

O QUADRO 8 apresenta os resultados da análise de correlação entre as medidas de cada piezômetro com a temperatura ambiente, onde os dados da temperatura foram defasados entre 1 e 20 semanas.

Semanas Defasadas	Temperatura x Instrumento		
	T x E1	T x E2	T x E3
1	-0,476	-0,487	-0,312
2	-0,561	-0,573	-0,402
3	-0,614	-0,628	-0,478
4	-0,664	-0,675	-0,547
5	-0,702	-0,711	-0,604
6	-0,735	-0,742	-0,655
7	-0,763	-0,767	-0,700
8	-0,781	-0,780	-0,733
9	-0,783	-0,780	-0,758
10	-0,769	-0,766	-0,767
11	-0,746	-0,739	-0,765
12	-0,703	-0,697	-0,749
13	-0,642	-0,637	-0,722
14	-0,571	-0,568	-0,688
15	-0,489	-0,491	-0,644
16	-0,397	-0,403	-0,589
17	-0,298	-0,307	-0,523
18	-0,200	-0,211	-0,450
19	-0,102	-0,112	-0,369
20	-0,003	-0,010	-0,282

QUADRO 8 - Análise de correlação entre medidas do instrumento e temperatura com defasagem do tempo

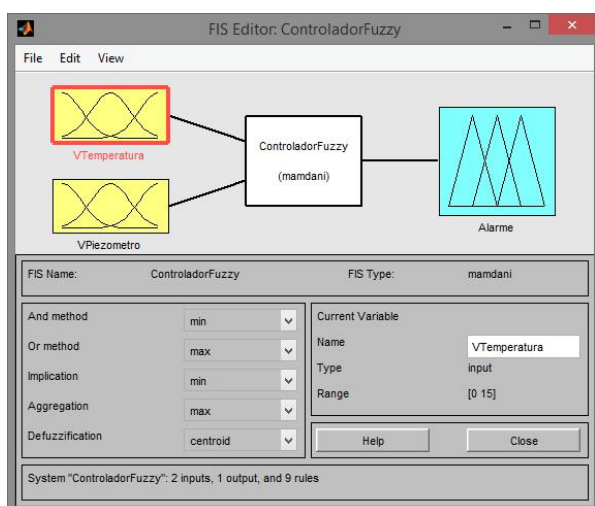
FONTE: O autor

De acordo com os resultados do QUADRO 8, foi utilizado neste trabalho a defasagem de 9 semanas para a comparação da temperatura ambiente com as medidas dos instrumentos, ou seja, o valor medido em um instrumento na semana i é comparado com o valor da temperatura de 9 semanas anteriores, isto é, semana $(i - 9)$.

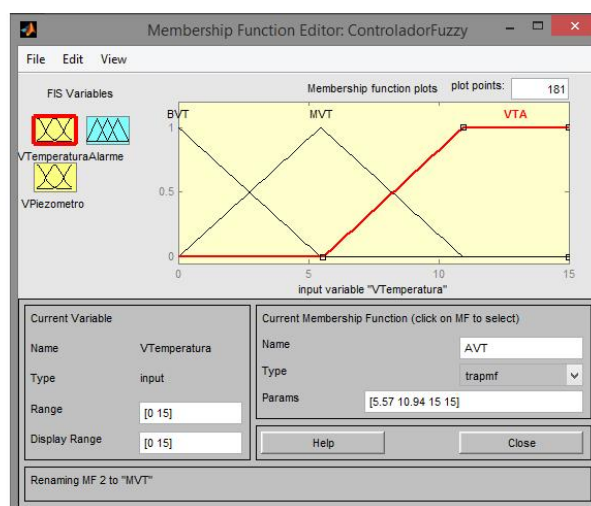
Os resultados obtido neste estudo condiz com os resultados dos trabalhos (PATIAS *et al.*, 2015) e (FIORINI *et al.*, 2001).

Após a definição da defasagem entre as grandezas, é iniciado o processo de construção do sistema *fuzzy* que classifica os pontos de mudanças detectados. Para isso, são gerados os vetores de variações dos dados (Seção 4.2.6) conforme a Equação 56 e calculado o máximo valor de cada um dos vetores de variação. Os valores máximos são utilizados para definir os conjuntos *fuzzy* que modelam os termos subjetivos “baixo”, “médio” e “alto” usados por especialistas no tratamento das variações medidas nos instrumentos e temperatura ambiente.

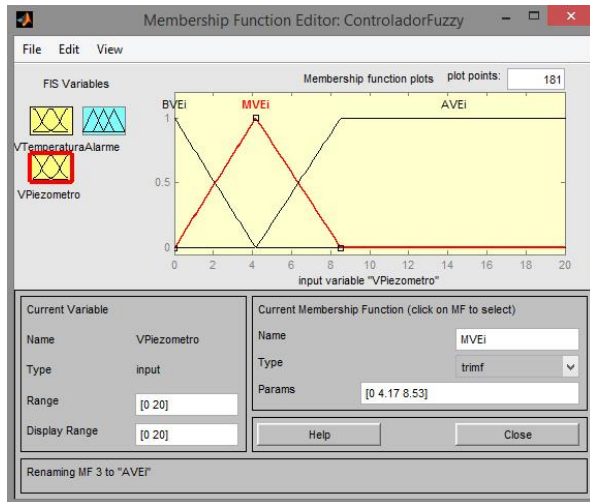
Neste trabalho, todo o sistema de controle *fuzzy* (fuzzificação, base de regras, inferência e defuzzificação), descrito na Seção 4.2.6 foi implementado no pacote *FUZZY LOGIC TOOLBOX* do *software* MATLAB R2013A. A FIGURA 5.3 apresenta as etapas desenvolvidas no *software* para produção do controlador *fuzzy*, onde: (a) indica as escolhas das entradas e saídas do controlador, dos operadores para os conectivos lógicos “E”, “OU”, agregação e implicação, e o método de defuzzificação; (b) os conjuntos *fuzzy* que modelam a Variação de Temperatura; (c) os conjuntos *fuzzy* que modelam a Variação da Medida do Instrumento; (d) os conjuntos *fuzzy* que modelam a saída Nível de Alerta; (e) a base de regras e (f) o funcionamento final do controlador *fuzzy*, onde as variáveis de entradas variação de temperatura e variação da medida do instrumento são aplicadas no controlador para gerar um valor numérico denotado nível *fuzzy* de alarme.



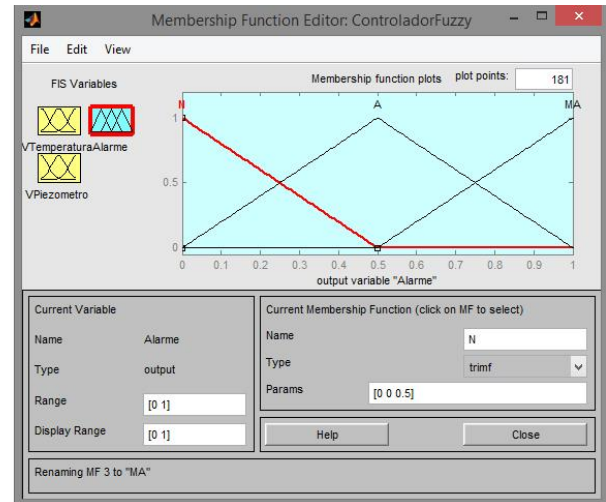
(a)



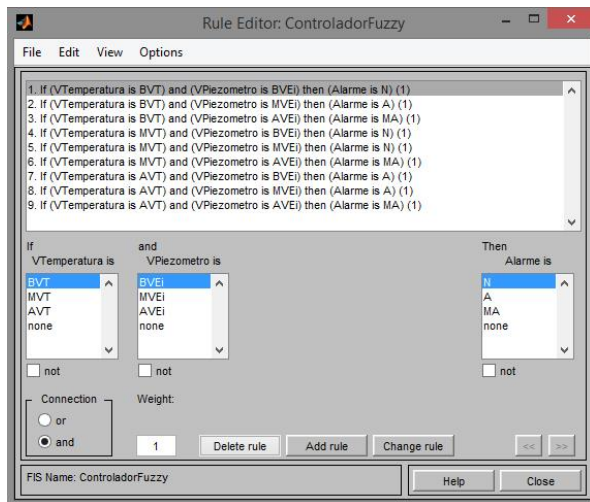
(b)



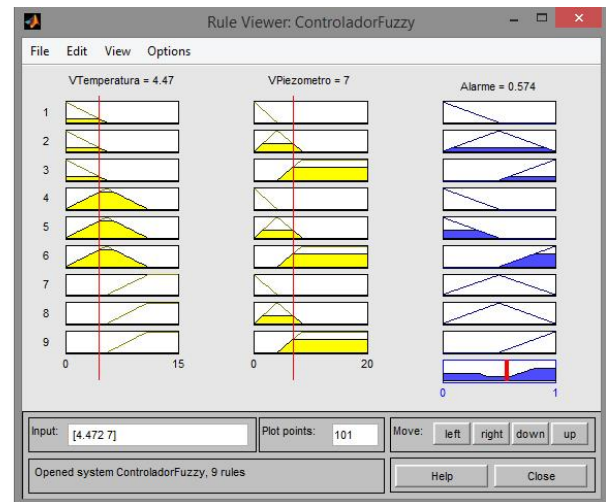
(c)



(d)



(e)



(f)

FIGURA 5.3 - Passo da construção do controlador *fuzzy* via pacote *FUZZY LOGIC TOOLBOX* do *software* MATLAB R2013A

FONTE: O autor

Após a construção dos controladores *fuzzy* para cada um dos sete instrumentos analisados, são calculados os níveis *fuzzy* de alerta para os pontos detectados como mudanças das séries temporais. Desse modo, para cada ponto indicado, é calculada a variação da medida do instrumento relativa ao ponto, a variação da temperatura de 9 semanas anteriores e aplicadas no controlador *fuzzy*, determinando o seu nível *fuzzy* de alerta.


Os pontos não detectados pela metodologia como mudança de comportamento da série temporal, são considerados “totalmente normais”, e assim, quantificados pelo valor mínimo possível de nível *fuzzy* de alerta, ou seja, 1/6.

Todo ponto da série temporal está relacionado a um nível *fuzzy* de alerta. A fim de apresentar graficamente os resultados obtidos com a aplicação do método nas

séries temporais, são calculados a média (\bar{x}) e o desvio padrão (σ) dos níveis *fuzzy* de alerta de todos pontos dados a partir da data em que ocorre a diminuição dos efeitos causados pelo enchimento do reservatório sobre a barragem (05/01/1997). Em seguida são definidas as seguintes cores para os gráficos:

- Verde: quando o nível *fuzzy* de alerta do ponto for menor que $\bar{x} + 2\sigma$;
- Amarelo: quando o nível *fuzzy* de alerta do ponto for maior ou igual a $\bar{x} + 2\sigma$ e menor que $\bar{x} + 4\sigma$;
- Vermelho: quando o nível *fuzzy* de alerta do ponto for maior ou igual a $\bar{x} + 4\sigma$.

Desse modo, os resultados obtidos pelos métodos de detecção e classificação dos pontos de mudança das séries temporais dos instrumentos de monitoramento definidos com eventos básicos da árvore de falhas do bloco D38 são ilustrados na FIGURA 5.4.






FIGURA 5.4 - Resultado do método de classificação via controlador fuzzy
 FONTE: O autor

Os gráficos apresentados na FIGURA 5.4, expõem um dos principais resultados para este estudo, pois, é de fácil entendimento que as variações obtidas nas medidas dos instrumentos de monitoramento no período de enchimento do reservatório ocorreram devido a mudança das força atuantes sobre a barragem, em especial, a pressão causada pelo enorme volume de água represada no lago, sendo assim, as variações medidas neste período de enchimento não tiveram como principal influência as variações da temperatura ambiente. Logo, espera-se, devido o foco do método proposto, que as variações ocorridas no período do enchimento sejam

detectadas e classificadas com alto nível de alerta. Observa-se que isso ocorre na maioria dos gráficos: nos quatro primeiros gráficos (eventos básicos E1, E2, E3 e E4) o período de enchimento encontra-se na cor vermelha, ou seja, nível *fuzzy* de alerta próximo do máximo; o evento básico E5 (medidor de vazão) não possui medidas para o período em análise; o gráfico do evento E7 apresenta as variações do período de enchimento como sendo de atenção (cor amarela); e o gráfico do evento E6 é o único que apresenta as variações do período de enchimento sendo consideradas normais, isso explica-se, devido as variações ocorridas no enchimento serem bem próximas as variações ocorridas durante todo tempo de medição.

Outros pontos apresentados em vermelho representam uma possível anormalidade ocorrida na medida do instrumento naquele período, indicando aos especialistas responsáveis pela monitoria que a variação medida no instrumento não está condizente com a variação da temperatura ambiente, o que exige maior atenção dos responsáveis no acompanhamento da região em que se encontra o instrumento. Muitas vezes, a classificação vermelha de um instrumento pode ser explicada por diversas situações, entre elas, erro de leitura ou mesmo falha do equipamento.

A partir da definição dos níveis *fuzzy* de alertas para cada ponto das séries temporais dos eventos básicos, é possível a aplicação da análise quantitativa na árvore de falhas conforme descrita na Seção 4.2.8. Assim, através da Equação 69, é calculado o nível *fuzzy* de alerta do evento topo para cada semana, ou seja, define-se, para cada semana, um valor numérico que descreve quantitativamente o comportamento do bloco D38 em relação aos movimentos de tombamento ou deslizamento.

Com o intuito de apresentar graficamente os pontos em que o bloco D38 apresenta maior possibilidade de mudança de comportamento, a FIGURA 5.5 é construída seguindo os mesmo critério de cores definido para os gráficos da FIGURA 5.4.

Tem-se pela FIGURA 5.5 que a análise da árvore de falhas do bloco D38 define 14 pontos com nível de atenção amarela e 3 pontos como sendo nível de atenção vermelho, destacando, como já era esperado, que um dos pontos do gráfico classificado com nível *fuzzy* de alerta vermelho representa as mudanças no comportamento do bloco D38 ocorridas no período de enchimento do lago, confirmando, novamente, a eficiência do modelo apresentado na proposta metodológica deste trabalho.




FIGURA 5.5 - Resultado da análise de árvore de falhas do bloco D38 da barragem de Itaipu
FONTE: O autor

Finalizando a análise quantitativa da árvore de falhas, é desenvolvido o método de medida importância descrito na Seção 4.2.9 da metodologia. Para isso, a Equação 70 é aplicada nos pontos classificados com níveis de alerta amarelo e vermelho. Os resultados estão descritos no QUADRO 9 a seguir.

Pontos Classificados com Nível de Atenção Vermelho		
Data	$\mathcal{N}(T)$	Eventos por Ordem de Importância – $Ei(FV_{Ei})$
31/10/1982	0,6121	$E4 (FV = 0,728) / E1, E2, E3, E5, E6, E7 (FV = 0,638)$
17/04/1983	0,7959	$E4 (FV = 0,728) / E7 (FV = 0,655) / E1, E2, E3, E5, E6 (FV = 0)$
12/06/1983	0,8336	$E4 (FV = 0,800) / E7 (FV = 0,643) / E1, E2, E3, E5, E6 (FV = 0)$
Pontos Classificados com Nível de Atenção Amarelo		
Data	$\mathcal{N}(T)$	Eventos por Ordem de Importância – $Ei(FV_{Ei})$
25/04/1982	0,4996	$E4 (FV = 0,666) / E7 (FV = 0,197) / E1, E2, E3, E5, E6 (FV = 0)$
11/08/1985	0,5000	$E4 (FV = 0,666) / E1, E2, E3, E5, E6, E7 (FV = 0)$
03/08/1986	0,5228	$E4 (FV = 0,681) / E7 (FV = 0,406) / E1, E2, E3, E5, E6 (FV = 0)$
24/08/1986	0,5000	$E4 (FV = 0,666) / E7 (FV = 0,306) / E1, E2, E3, E5, E6 (FV = 0)$
18/10/1987	0,4995	$E4 (FV = 0,666) / E1, E2, E3, E5, E6, E7 (FV = 0)$
25/10/1987	0,5000	$E4 (FV = 0,666) / E1, E2, E3, E5, E6, E7 (FV = 0)$
17/09/2000	0,5000	$E4 (FV = 0,666) / E1, E2, E3, E5, E6, E7 (FV = 0)$
03/03/2002	0,5068	$E4 (FV = 0,671) / E7 (FV = 0,650) / E1, E2, E3, E5, E6 (FV = 0)$
10/03/2002	0,5079	$E4 (FV = 0,671) / E7 (FV = 0,615) / E1, E2, E3, E5, E6 (FV = 0)$
09/11/2003	0,4997	$E4 (FV = 0,666) / E1, E2, E3, E5, E6, E7 (FV = 0)$
01/02/2004	0,5076	$E4 (FV = 0,671) / E7 (FV = 0,075) / E1, E2, E3, E5, E6 (FV = 0)$
08/02/2004	0,5116	$E4 (FV = 0,674) / E7 (FV = 0,077) / E1, E2, E3, E5, E6 (FV = 0)$
15/02/2004	0,5067	$E4 (FV = 0,671) / E7 (FV = 0,068) / E1, E2, E3, E5, E6 (FV = 0)$
28/03/2004	0,4996	$E4 (FV = 0,666) / E7 (FV = 0,118) / E1, E2, E3, E5, E6 (FV = 0)$

QUADRO 9 – Resultados da aplicação de medida de importância nos pontos classificados com níveis de atenção vermelho e amarelo

FONTE: O autor

Tem-se pelo QUADRO 9 que o evento que tem mais importância nos pontos detectados e classificados com maior nível de atenção é o E4, medidas do instrumento de monitoramento realizadas pelo extensômetro EM-D-13. Isso ocorre, devido ao fato de que as medidas geradas pelo extensômetro ser consideradas pelos especialistas que construíram a árvore de falhas, importante parâmetro para a detecção de movimentos do bloco. Por isso, observa-se que o evento E4 aparece em todos os conjuntos de cortes mínimos definidos na Equação 50.

Outro item importante, é que a grande maioria dos pontos são considerados normais, pois, de fato, a barragem de Itaipu apresenta uma grande estabilidade em seu comportamento em relação aos controles estabelecidos em seu projeto.

Em seguida, é feita a conclusão do trabalho em relação a todos os resultados apresentados destacando o potencial do método desenvolvido.

6 CONCLUSÃO

Neste trabalho, é proposto um método de análise de árvore de falhas através da detecção e classificação automática de mudança de comportamentos em séries temporais geradas por instrumentos de monitoramento usados no gerenciamento da segurança de barragens. A eficiência do método foi testada através da aplicação em séries temporais reais, utilizadas no monitoramento da barragem de Itaipu. Os resultados obtidos se mostram satisfatórios, já que os pontos detectados e classificados pelo método com o maior nível de alerta, teve sua ocorrência dada no período de enchimento do reservatório, onde de fato, toda a estrutura da barragem teve grande mudança em seu comportamento sem ter a variação da temperatura como sendo a principal responsável pela mudança.

O processo de detecção de mudança de comportamento em séries temporais baseado em uma abordagem neuro/fuzzy/bayesiana mostra-se uma fase importante da metodologia, pois seleciona de forma eficiente os pontos que de fato merecem atenção em relação a possível mudança no comportamento do bloco da barragem.

A fase de classificação realizada através de um sistema de controle *fuzzy* baseado em informações adquiridas pela experiência de especialista apresentou resultados satisfatórios, destacando o fato de que ao longo da operação da Usina Hidrelétrica de Itaipu, o comportamento da barragem é considerado normal e que as variações encontradas nas medidas geradas pelos instrumentos de monitoramento podem ser explicadas, em geral, pelas variações que ocorrem na temperatura ambiente da região, exceto no período de enchimento do lago, em que o carregamento da barragem, foi a principal influência nas variações dos instrumentos, fato detectado e classificado pelo método.

Portanto, em grandes barragens, igual a de Itaipu, a empresa necessita revisar manualmente a mudança de comportamento em um número muito grande de instrumentos, isto justifica o desenvolvimento e a aplicação de um método capaz de realizar esta análise de forma automática e eficiente, pois acelera o processo de decisões a serem tomadas, melhorando o gerenciamento de segurança da barragem. Sendo potencialmente utilizável em situações especiais como: sismos, temperatura muito baixa, enchentes e outros.

REFERÊNCIAS

- ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Ações e Seguranças nas Estruturas (NBR 8681)**. 2003.
- ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Confiabilidade e Manutenibilidade (NBR 5462)**. 2004.
- BANDO, F. M. **Sistemas Fuzzy e Aproximação Universal**. 76p. Dissertação (Mestrado em Matemática) - IMECC, UNICAMP, Campinas - SP: 2002.
- BARROS, L. C. DE. **Sobre Sistemas Dinâmicos Fuzzy - Teoria e Aplicações**. 114 p. Tese (Doutorado em Matemática Aplicada) - IMECC, UNICAMP, Campinas - SP: 1997.
- BARROS, L. C. DE; BASSANEZI, R. C. **Tópicos de Lógica Fuzzy e Biomatemática**. 2a. ed. Campinas - SP: Unicamp/IMECC, 2010.
- BARRY, D.; HARTIGAN, J. A. **A Bayesian Analysis for Chance Point Problems**. *Jornal of the American Statistical Association*, v. 88(421), p. 309–319, 1993.
- BARTYS, M.; PATTON, R.; SYFERT, M.; HERAS, S. DE LAS; QUEVEDO, J. **Introduction to the DAMADICS Actuator FDI Benchmark Study**. *Control Engineering Practice*, v. 14(6), p. 577-596, 2006.
- BATISTA, R. D. A. **Busca de Padrões em Séries Temporais**. Monografia (Graduação em Ciência da Computação) - Instituto de Informática, UFRS, Porto Alegre - RS: 2010.
- BEER, F. P.; JOHNSTON, E. R. **Mecânica Vetorial para Engenheiros - Estática**. 5a. ed. São Paulo - SP: McGraw-Hill, 1991.
- BOX, G. E. P.; TIAO, G. C. **Bayesian Inference in Statistical Analysis**. New york: J. Wiley, 1992.
- BRASIL. **Lei no. 12.334, de 20 de setembro 2010**.
- CAI, K. Y. **Introduction to Fuzzy Reliability**. Boston: Kluwer Academic, 1996.
- CALADO, J. M. F.; KORBICZ, J.; PATTAN, K.; PATTON, R. J.; COSTA, J. M. G. S. **Soft Computing Approaches to Fault Diagnosis for Dynamic Systems**. *European Journal Control*, v. 7(2-3), p. 248-286, 2001.

CBDB. **Sistemas de Monitoramento Automático das Barragens:**

Recomendações e Exemplos. Comitê Brasileiro de Barragens - Boletim 118, p. 176, 2005.

CBGB. **Auscultação e Instrumentação de Barragens no Brasil.** II Simpósio Sobre Instrumentação de Barragens, v. 1, p. 123, 1996.

D'ANGELO, M. F. S. V. **Uma Nova Formulação Fuzzy/Bayesiana para Detecção de Ponto de Mudança em Séries Temporais: Aplicações na Detecção de Falhas Incipientes.** Tese (Doutorado em Engenharia Elétrica) - UFMG, Belo Horizonte - MG: 2010.

D'ANGELO, M.; PALHARES, R.; TAKAHASHI, R.; LOSCHI, R. **Fuzzy/Bayesian change point detection approach to incipient fault detection.** IET Control Theory and Applications, v. 5, p. 539, 2011a.

D'ANGELO, M.; PALHARES, R.; TAKAHASHI, R.; LOSCHI, R.; BACCARINI, L.; CAMINHAS, W. **Incipient fault detection in induction machine stator-winding using a fuzzy-bayesian change point detection approach.** Applied Soft Computing, v. 11, p. 179–192, 2011b.

DAI, X.; GAO, Z.; BREIKIN, T.; WANG, H. **Zero Assignment for Robust H_2/H_∞ Fault Detection Filter Design.** IEEE Transactions on Signal Processing, v. 40(5), p.1349-1360, 2009.

DESHPANDE, A. **Fuzzy fault tree analysis: revisited.** International Journal of System Assurance Engineering and Management, v. 2, n. 1, p. 3-13, 2011.

DING, Y.; YU, D. **Estimation of failure probability of oil and gas transmission pipelines by fuzzy fault tree analysis.** Journal of Loss Prevention in the Process Industries, v. 12, n. 2, p. 83-88, 2005.

DUBOIS, D.; PRADE, H. **Fuzzy Sets and Systems: Theory and Applications.** Academic Press, 1980.

EHLERS, R. **Introdução à Inferência Bayesiana.** Notas de Aula, São Paulo - SP: USP, 2011.

ELETROBRÁS. **Critérios de Projeto Civil de Usinas Hidrelétricas.** Centrais Elétricas Brasileiras S.A. - ELETROBRÁS, p. 278, 2003.

FERDOUS, R.; KHANA, F.; VEITCHA, B.; AMYOTTE, P. **Methodology for Computer Aided Fuzzy Fault Tree Analysis.** Process Saf Environ Prot, v. 87(4), p. 217-226, 2009.

FIORINI, A.; PORTO, E.; PAREDES, M.; PIASENTIN, C. **Barragem de Itaipu - Comparação de Comportamento dos Diferentes Tipos de Barragem de Concreto.** XXXIV Seminário Nacional de Grandes Barragens, Fortaleza - CE, 2001.

FURUTA, H.; SHIRAISHI, N. **Fuzzy importance in fault tree analysis**. Fuzzy Sets and Systems, v. 12, n. 2, p. 205-213, 1984.

GUIMARÃES, A. C. F.; LAPA, C. M. F. **Fuzzy inference to risk assessment on nuclear engineering systems**. Applied Soft Computing Journal, v. 7, n. 2007, p. 17-28, 2007.

GUIMARÃES, A. C. F. **Uma Metodologia para Análise de Confiabilidade baseada em Árvore de Falhas e Lógica Fuzzy**. p. 209. Tese (Doutorado em Ciências em Engenharia Civil), COPPE, UFRJ, Rio de Janeiro - RJ: 1997.

HADIPRIONO, FABIAN C.; FUJINO, T. **New gate operations of fuzzy fault tree analysis**. Proceedings of the third IEEE conference on fuzzy systems, p. 1246-1251, 1994.

HASTING, K. W. **Monte Carlo Sampling Methods Using Markov Chains and Their Applications**. Biometrika, v. 57, p. 97-109, 1970.

HINKEY, D. V. **Inference About the Change From Cumulative Sum Test**. Biometria, v. 26, p. 279-284, 1971.

ICOLD. **Critérios de Projeto Civil de Usinas Hidrelétricas**. Centrais Elétricas Brasileiras S.A. - ELETROBRÁS, p. 279, 2003.

ISERMANN, R. **Supervision, fault-detection and fault-diagnosis methods - An introduction**. Control Engineering Practice, v. 5, n. 5, p. 639-652, 1997.

ITAIPU. **Usina Hidrelétrica de Itaipu: Aspectos Técnicos das Estruturas**. Foz do Iguaçu - PR: 2008.

ITAIPU: USINA HIDRELÉTRICA. **Projeto: Aspectos de Engenharia**. Foz do Iguaçu - PR: 2009.

JAMES, B. R. **Probabilidade: Um Curso em Nível Intermediário**. Rio de Janeiro: IMPA - Coleção Projeto Euclides, 2011.

JIANG, C.; ZHOU, D. H. **Fault Detection and Identification for Uncertain Linear Time-Delay Systems**. Computer and Chemical Engineering, v. 30, p. 228-242, 2005.

KENARANGUI, R. **Event-Tree Analysis by Fuzzy Probability**. IEEE Transactions on Reliability, v. 40, n. 1, p. 120-124, 1991.

KIM, C. E.; JU, Y. J.; GENS, M. **Multilevel fault tree analysis using fuzzy numbers**. Computers Ops Res, v. 23, n. 7, p. 695-703, 1996.

KOHONEN, T. **Self-organized formation of topologically correct feature maps**. Biological Cybernetics, v. 43, p. 59-69, 1982.

KOHONEN, T. **The self-organizing map**. Proceedings of the IEEE, v. 78, n. 9, p. 1464-1480, 1990.

KUMAR, N.; BORM, J. H.; KUMAR, A. **Reliability analysis of waste clean-up manipulator using genetic algorithms and fuzzy methodology**. Computers and Operations Research, v. 39, n. 2, p. 310-319, 2012.

LIN, C. T.; WANG, M. J. **Hybrid fault tree analysis using fuzzy sets**. Reliability Engineering & System, v. 58, n. 1997, p. 205-213, 1998.

LO, C. H.; FUNG, E. H. K.; WONG, Y. K. **Intelligent Automatic Fault Detection for Actuator Failures in Aircraft**. IEEE Transactions on Industrial Informatics, v. 5(1), p. 50-55, 2009.

LOSCHI, R. H.; CRUZ, F. R. B. **Extension to the Product Partition Model: Computing the Probability of a Change**. Computational Statistics and Data Analysis, v. 42(2), p. 255–268, 2005.

MAHMOOD, Y. A.; AHMADI, A.; VERMA, A. K.; SRIVIDYA, A.; KUMAR, U. **Fuzzy fault tree analysis: a review of concept and application**. International Journal of System Assurance Engineering and Management, v.4, n. 1, p. 19-32, 2013.

MAMDANI, E. H.; ASSILIAN, S. **An Experiment in Linguistic Synthesis With a Fuzzy Logic Controller**. Int. J. Man-Machine Studies, v.7, 1975.

MAO, GUO-ZHU; TU, JIA-WEI; DU, H. **Reliability Evaluation Based on Fuzzy Fault Tree**. IEEE 17th International Conference on Industrial Engineering and Engineering Management (IE&EM), v. 300072, p. 963-966, 2010.

MAST, T. A.; REED, A. T.; YURKOVICH, S.; ASHBY, M.; ADIBHATLA, S. **Bayesian Belief Networks for Fault Identification in Aircraft Gas Turbine Engines**. IEEE International Conference on Control Applications, p. 39-44, Hawaii, USA, 1999.

MATSUMOTO, E. Y. **Matlab R2013A: Teoria e Programação - Guia Prático**. 1a. Edição, ed. Érica, 2013.

METROPOLIS, N.; ROSENBLUTH, A. W.; ROSENBLUTH, M. N.; TELLER, H. A.; TELLER, E. **Equations of State Calculations by Fast Computing Machines**. Journal of Chemical Physics, v. 21, p. 1087–1092, 1953.

MISRA, K. B. **Reliability Analysis and Prediction: A Methodology Oriented Treatment**. Elsevier Science B.V, 1992.

MISRA, K. B. **New Trends in System Reliability Evaluation**. Amsterdam: Elsevier Science B.V, 1993.

MISRA, K. B.; WEBER, G. G. **A New Method for Fuzzy Fault Tree Analysis**. Microelectronics And Reliability, v. 29, n. 2, p. 195-216, 1989.

- MOREIRA, F. DE S. **Detecção de pontos de mudança em séries temporais utilizando uma formulação Neural/Fuzzy/Bayesiana: Aplicação na detecção de falhas**. Dissertação (Mestrado em Engenharia Elétrica), UFMG, Belo Horizonte - MG: 2011.
- NASA. **Fault tree handbook with aerospace applications**. Washington, DC: NASA Headquarters, 2002.
- NEUMANN JR, C.; OSAKO, C.; PATIAS, J.; PORCHETTO, C. **Reflexos da Lei de Segurança de Barragens na Itaipu Binacional**. Rio de Janeiro - RJ: In: XXVIII SEMINÁRIO NACIONAL DE GRANDES BARRAGENS, p. 1-11, 2011.
- NGUYEN, H. T.; WALKER, E. A. **A First Course in Fuzzy Logic**. CRC Press, 1997.
- NOGUEIRA, D. A.; SÁFADI, T.; FERREIRA, D. F. **Avaliação de Critérios de Convergência para o Método de Monte Carlo via Cadeias de Markov**. Revista Brasileira de Estatística, v. 65, p. 59–88, 2004.
- NORRIS, J. R. **Markov Chains**. Cambridge University Press, 1997.
- ONISAWA, T. **An Approach to Human Reliability in Man-Machine Systems using Error Possibility**. Fuzzy Sets and Systems, v. 27, p. 87-103, 1988.
- ONISAWA, TAKEHISA; KACPRZYK, J. **Reliability and Safety Analyses under Fuzziness**. Physical ed. Heidelberg. 1995.
- ORTEGA, N. R. S. **Aplicação da Teoria de Conjuntos Fuzzy a Problemas da Biomedicina**. Tese (Doutorado em Ciências) - Instituto de Física, USP, São Paulo - SP: 2001.
- PAN, H.; YUN, W. **Fault tree analysis with fuzzy gates**. Computers and industrial engineering, v. 33, n. 97, p. 569-572, 1997.
- PATIAS, J. **Zoneamento Geotécnico Com Base Em Krigagem Ordinária E Equações Multiquádricas : Barragem de Itaipu**. Tese (Doutorado em Ciências) - Escola de Engenharia de São Carlos da Universidade Estadual de São Paulo Instituto de Física, USP, São Carlos - SP: 2010.
- PATIAS, J.; MATOS, S. F.; ROYER, J. C.; FARIA, E. F. **Vazões de Infiltração através da Barragem de Itaipu**. XXX Seminário Nacional de Grandes Barragens, Foz do Iguaçu, PR, 2015.
- PAULINO, C. D.; TURKMAN, A. A.; MURTEIRA, B. **Estatística Bayesiana**. Lisboa: Fundação Calouste Gulbenkian, 2003.
- PEDRYCZ, W. **Fuzzy Clustering with Partial Supervision**. Pattern Recognition Letters, v. 3(1), p. 13–20, 1985.

PLOIX, S.; ADROT, O. **Parity Relations for Linear Uncertain Dynamic Systems**. Automática, v. 42(9), p. 1553-1562, 2006.

PUIG, V.; STANCU, A.; NEJJARI, T.; QUEVEDO, J.; PATTON, R. **Passive Robust Fault Detection Using Interval Observers: Application to the DAMADICS Benchmark Problem**. Control Engineering Practice, v. 14(6), p. 621-633, 2006.

REN, Y.; KONG, L. **Fuzzy multi-state fault tree analysis based on fuzzy expert system**. The Proceedings of 2011 9th International Conference on Reliability, Maintainability and Safety, p. 920-925, 2011.

RIGATOS, G.; ZHANG, Q. **Fuzzy Model Validation Using the Local Statistical Approach**. Fuzzy Sets and Systems, v. 160(7), p. 882-904, 2009.

RUGGIERO, M. A. G.; LOPES, V. L. R. **Cálculo Numérico: Aspectos Teóricos e Computacionais**. 2a. Edição, ed. Pearson Makron Books, São Paulo, Brasil. 1996.

SANTOS, R. N. C. DOS. **Enquadramento das Análises de Riscos em Geotecnia**. Dissertação (Mestrado em Geotecnia para Engenharia Civil) - Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, Lisboa. 2006.

SAWYER, J. P.; RAO, S. S. **Fault Tree Analysis of Fuzzy Mechanical Systems**. Fault tree analysis of fuzzy mechanical systems, v. 34, n. 4, p. 653-667, 1994.

SAYÃO, A. **A segurança das barragens brasileiras**. São Paulo, 10 de junho de 2009. Disponível em: <http://ie.org.br/site/noticias/exibe/id_sessao/5/id_noticia/1643/A-seguranca-das-barragens-brasileiras>. Acesso em: 29/11/2015.

SILVA, L. N. DE C. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais**. Dissertação (Mestrado em Engenharia Elétrica) - FEE/UNICAMP, Campinas - SP. 1998.

SILVEIRA, J. F. A. **Instrumentação e Comportamento de Fundações de Barragens de Concreto**. São Paulo - SP: Oficina de Textos, 2003.

SIMÕES FILHO, S. **Análise de Árvore de Falhas Considerando Incertezas na Definição dos Eventos Básicos**. Tese (Doutorado em Ciências em Engenharia Civil) - COPPE/UFRJ, Rio de Janeiro - RJ: 2006.

SINGER, D. **RELIABILITY ANALYSIS**. Fuzzy Sets and Systems, v. 34, n. 2, p. 145-155, 1990.

SOUZA, R. N. O. **Detecção de Falha Aplicada na Atualização de Probabilidade de Falha**. Dissertação (Mestrado em Engenharia Elétrica) - UFMG, Belo Horizonte - MG. 2013.

SURESH, P. V.; BABAR, A.K.; RAJ, V. **Uncertainty in fault tree analysis: A fuzzy approach**. Fuzzy Sets and Systems, v. 83, n. 2, p. 135-141, 1996.

TANAKA, H.; FAN, L.T.; LAI, F.S.; TOGUCHI, K. **Fault-Tree Analysis by Fuzzy Probability**. IEEE Transactions on Reliability, v. R-32, n. 5, p. 453-457, 1983.

TANG, F. **A Model-Based Bayesian Fault Diagnostic Systems: With Applications to Semicondutor Manufacturing Processes**. PhD Thesis, Carnegie Mellon University, 2000.

U. S. NUCLEAR REGULATORY COMMISSION. **Fault Tree Handbook**. Springfield, VA: 1981.

VILLWOCK, R. **Técnicas de Agrupamento e de Hierarquização no Contexto de KDD - Aplicação a Dados Temporais de Instrumentação Geotécnica - Estrutura da Usina Hidrelétrica de Itaipu**. Tese (Doutorado em Ciências) Programa de Pós-Graduação em Métodos Numéricos em Engenharia, UFPR, Curitiba - PR. 2009.

WEBER, D. P. **Fuzzy Weibull for risk analysis**. Proceedings of Annual Reliability and Maintainability Symposium (RAMS), p. 456-461, 1994.

WITCZAK, M.; KORBICZ, J.; MRUGALSKI, M.; PATTON, R. J. **A gmdh Neural Network-Based Approach to Robust Fault Diagnosis: Application to the DAMADISC benchmark problem**. Control Engineering Practice, v. 14(6), p. 671-683, 2006.

ZADEH, L. A. **Fuzzy Sets**. Information and Control, v. 8, p. 338-353, 1965.

ZADEH, L. A. **Fuzzy Sets as a Basis for a theory of possibility distributions**. Fuzzy Sets and Systems, v. 102, p. 135-155, 1978.

ZIMMERMANN, H. J. **Fuzzy set theory**. Wiley Interdisciplinary Reviews: Computational Statistics, v. 2, p. 317-332, 2010.

ZONOUZ, S. A.; MIREMADI, S. G. **A fuzzy-monte carlo simulation approach for fault tree analysis**. Reliability and Maintainability Symposium, p. 428-433, 2006.

APÊNDICES

APÊNDICE 1: ALGORITMO DE TRATAMENTO DOS DADOS

Algoritmo para o tratamento dos dados fornecidos pela equipe responsável pelo monitoramento da segurança da barragem de Itaipu, programado no *software* MATLAB R2013A.

```
% TRATAMENTO DOS DADOS
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: Tratamento

clear;
clc;

% Passo 01: Carregar Dados -----
% Obs.: Os arquivos com as séries Temporais de Dados devem conter
%       apenas duas colunas: 1a. Datas convertidas em números e
%                               2a. Medidas.
A1=xlsread('Dados Originais.xlsx');
nA1=size(A1,1);

% Passo 02: Eliminar Medidas de um Mesmo Dia -----
A2(1,1:2)=A1(1,1:2);
k=2;
for i=2:nA1
    d=A1(i,1)-A1(i-1,1);
    if d>=1
        A2(k,1:2)=A1(i,1:2);
        k=k+1;
    end
end

% Passo 03: Criar Medidas Não Realizadas -----
% Obs.: Os dados são gerados através de INTERPOLAÇÃO LINEAR.
nA2=size(A2,1);
A3(1,1:2)=A2(1,1:2);
k=2;
for i=2:nA2
    d=A2(i,1)-A2(i-1,1);
    for j=1:d
        A3(k,1)=(A2(i,1)-A2(i-1,1))/d+A3(k-1,1);
        A3(k,2)=(A2(i,2)-A2(i-1,2))/d+A3(k-1,2);
        k=k+1;
    end
end

% Passo 04: Dados Formados com Médias por Períodos-----
nA3=size(A3,1);
med=7;
vi=(fix((A3(1,1)-29247)/med)+1)*med+29247;
InA=find(A3==vi)+1;
q=fix((nA3+1-InA)/med);
for i=1:q
    A4(i,1:2)=[A3(InA-1+med*i,1),mean(A3(InA+med*(i-1):InA-1+med*i,2))];
```

```
end
```

```
xlswrite('Dados Tratados',A4);
```

```
%-----
```

APÊNDICE 2: ALGORITMO DA REDE DE KOHONEN

Algoritmo para *clustering* de pontos de uma série temporal via redes neurais de Kohonen, programado no *software* MATLABR2013A.

```
% Clusterização via Rede de Kohonen
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: Tratamento

% Passo 01: Inicialização-----
S; % Subsequência determinada na Técnica de Janela
% Deslizante
Nneur=2; % Número de Neurônios Iniciais
Iter=1000; % Número de Iterações
r=1; % Raio de Atualização da Vizinhaça
alpha=0.1; % Taxa de Aprendizagem Inicial

% Passo 02: Pesos Iniciais dos Neurônios-----
w(1)=min(S);
w(2)=(3*min(S)-max(S))/2;

% Passo 03: Dados da Subsequência escrita de forma aleatória-----
OrdemAleat=randperm(T);
for i=1:T
    yAl(i,1)=S(OrdemAleat(i)); % yAl = Subsequência y distribuída aleatoriamente
end

% Passo 04: Determinação dos Centros dos Clusters-----
Nn=Nneur; % Nn = Número Novo de Neurônios
Elim=1; % Eliminação de Neurônios não Associados
% (Elim = 0 (Não Elimina) ou 1 (Elimina))
while Elim==1
    for epoca=1:Iter
        id=zeros(1,Nn); % Índice de Desempenho
        for t=1:T
            L=1; % Índice do Neurônio Vencedor

            % 04.1 - Cálculo do Neurônio com a Menor Distância (Euclidiana)
            for i=2:Nn
                if abs(yAl(t)-w(i))<abs(yAl(t)-w(L));
                    L=i;
                end
            end

            % 04.2 - Atualização da Vizinhaça do Neurônio Vencedor
            for i=1:Nn
                if L-r<i & i<L+r
                    w(i)=w(i)+alpha*(yAl(t)-w(i));
                end
            end

            % 04.3 - Contando o Desempenho de Cada Neurônio
```

```

        id(L)=id(L)+1;

    end

    % 04.4 - Atualização da Taxa de Aprendizagem
    alpha=0.1-0.09*epoca/Iter; % Decrescimento Linear entre 0.1 e 0.01
end

Passo 05: Verificando se algum neurônio não teve associação-----
if min(id)~0
    % 05.1 - Apresentação do Conjunto dos Centros dos Clusters
    for i=1:Nn
        C(i)=w(i);
    end

    % 05.2 - Identificação de cada ponto da Série com o seu respectivo Centro
    for i=1:T
        IC(i)=1;
        for j=1:Nn
            if abs(S(i)-C(j))<abs(S(i)-C(IC(i)))
                IC(i)=j;
            end
        end
    end
    Existe=1;
    Fuzzificacao;
else
    Existe=0;
end

%-----

```

APÊNDICE 3: ALGORITMO PARA A FUZZIFICAÇÃO DA SÉRIE TEMPORAL

Algoritmo para transformação de uma série temporal com distribuição beta através de agrupamento *fuzzy* programado no *software* MATLAB R2013A.

```

% Fuzzificação de uma Série Temporal
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: Fuzzificacao

Passo 01: Importar Dados-----
% S=xlsread('Subsequencia.xlsx'); % Subsequência escolhida
n=size(S,1);

Passo 02: Definição da Função de Pertinência-----
for t=1:n
    D(t)=0;
    for i=1:2
        D(t)=D(t)+(S(t)-C(i))^2; % Denominador das funções Pertinências
    end
end
for t=1:n
    mi(1,t)=1-((S(t)-C(1))^2)/D(t);
end
MetropolisHastings

%-----

```

APÊNDICE 4: ALGORITMO METROPOLIS-HASTINGS

Algoritmo para a detecção do ponto de mudança de uma série temporal com via Metropolis-Hastings programado no *software* MATLAB R2013A.

```
% Algoritmo Metropolis-Hastings (Simulação de Monte Carlo via Cadeias de Markov)
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: MetropolisHastings

% Passo 01: Importar Dados-----
y=mi; % Nova Subsequência Transformada pela Fuzzificação
n=size(y,1);

% Passo 02: Valores Iniciais -----
R=1000; % No. De Iterações
a(1)=rand;
b(1)=rand;
c(1)=rand;
d(1)=rand;
m(1)=unidrnd(n,1);

% Passo 03: Valores Sorteados-----
for i=1:R
    av=a(i);
    bv=b(i);
    cv=c(i);
    dv=d(i);
    mv=m(i);

    % 03.1: Determinação do parâmetro (a) -----
    an=rand;
    arazao=(( (av/an)^0.9*exp(-0.1*(an-
av)))^2)*((gamma(an+bv)*gamma(av)/(gamma(av+bv)*gamma(an)))^mv)*prod(y(1:mv).^ (an-
av));
    aalpha=min(1,arazao);
    if aalpha>=rand
        a(i+1)=an;
    else
        a(i+1)=av;
    end

    % 03.2: Determinação do parâmetro (b) -----
    bn=rand;
    brazao=(( (bv/bn)^0.9*exp(-0.1*(bn-
bv)))^2)*((gamma(av+bn)*gamma(bv)/(gamma(av+bv)*gamma(bn)))^mv)*prod((1.-
y(1:mv)).^(bn-bv));
    balpha=min(1,brazao);
    if balpha>=rand
        b(i+1)=bn;
    else
        b(i+1)=bv;
    end

    % 03.3: Determinação do parâmetro (c) -----
    cn=rand;
    crazao=(( (cv/cn)^0.9*exp(-0.1*(cn-
cv)))^2)*((gamma(cn+dv)*gamma(cv)/(gamma(cv+dv)*gamma(cn)))^(n-
mv))*prod(y(mv+1:n).^ (cn-cv));
    calpha=min(1,crazao);
    if calpha>=rand
        c(i+1)=cn;
    else
```

```

        c(i+1)=cv;
    end

    % 03.4: Determinação do parâmetro (d) -----
    dn=rand;
    drazao=((dv/dn)^0.9*exp(-0.1*(dn-
dv)))^2*(gamma(cv+dn)*gamma(dv)/(gamma(cv+dv)*gamma(dn)))^(n-mv))*prod((1.-
y(mv+1:n)).^(dn-dv));
    dalpha=min(1,drazao);
    if calpha>=rand
        d(i+1)=dn;
    else
        d(i+1)=dv;
    end

    % 03.5: Determinação do parâmetro (m) -----
    v0=max(mv-fix(0.15*n),0);
    v1=min(mv+fix(0.15*n),n);
    mn=fix(v0+(v1-v0)*rand);
    mrazao=((gamma(av+bv)/(gamma(av)*gamma(bv)))^(mn-
mv))*((gamma(cv+dv)/(gamma(cv)*gamma(dv)))^(mv-mn))*prod(y(1:mn).^(av-
1))*prod((1.-y(1:mn)).^(bv-1))*prod(y(mn+1:n).^(cv-1))*prod((1.-
y(mn+1:n)).^(dv-1)))/((prod(y(1:mv).^(av-1))*prod((1.-y(1:mv)).^(bv-
1))*prod(y(mv+1:n).^(cv-1))*prod((1.-y(mv+1:n)).^(dv-1))));
    malpha=min(1,mrazao);
    if malpha>=rand
        m(i+1)=mn;
    else
        m(i+1)=mv;
    end
end

Passo 04: Determinação do Ponto de Mudança -----
pm=mode(m);          % Ponto De Mudança = moda dos valores de m

%-----

```

APÊNDICE 5: ALGORITMO PARA A TÉCNICA DE JANELA DESLIZANTE

Algoritmo para a técnica de janela deslizante programado no *software* MATLAB

R2013A.

```

% Técnica de Janela Deslizante
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: JanelaDeslizante

clear;
clc;

% Passo 01: Importar Dados -----
A5=xlsread('Dados Tratados.xls');          % Série Total
nA5=size(A5,1);
T=100;                                     % Tamanho da Subsequência

% Passo 02: Construção da Subsequência -----
in=1;
k=1;
while in+T<=nA5
    for j=1:T

```



```

        S(j)=A5(in-1+j,2);                % SubSequência
    end

% Passo 03: Detecção das Mudanças em cada Subsequência -----
    RedeKohonen;                          % Clusterização por Rede de Kohonen

% Passo 04: Deslizamento da Janela -----
    if Existe==0
        in=in+T;
    else
        PM(k)=pm+(in-1);
        in=PM(k);
        k=k+1;
    end
end

%-----

```

APÊNDICE 6: ALGORITMO DE CLASSIFICAÇÃO VIA CONTROLADOR *FUZZY*

Algoritmo para a construção de um controlador *fuzzy* responsável pela classificação de nível de alerta dos pontos de mudança detectados, programado no *software* MATLAB R2013A.

```

% Classificação dos Pontos de Mudança em Relação a Níveis de Alerta
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: ClassificacaoFuzzy

clear;
clc;

Passo 01: Importar Dados -----
A6=xlsread('Dados Tratados do Evento Ei.xls');
B5=xlsread('Temperatura Ambiente.xls');
PM=xlsread('Pontos de Mudança Detectados do Evento Ei.xls');
nA6=size(A6,1);
nB6=size(B5,1);
nPM=size(PM,1);

% Passo 02: Análise de Correlação entre os Dados -----
InA=find(A6==35435);          % Início dos Dados para Análise
InB=find(B6==35435);
% InA=find(A5==38011);        % Para E5 (Medidor de Vazão)
% InB=find(B5==38011);
ND=400; % Qtidade de Dados para Análise
QD=20;  % Qtidade de Deslocamento
for i=1:QD
    X=A6(InA-1+i:InA+ND-2+i,2); % Evento Ei
    Y=B6(InB:InB+ND-1,2);       % Temperatura
    C=corrcoef(X,Y);
    Corr(i,1:2)=[i,C(1,2)];
    CorrAbs(i,1:2)=abs(Corr(i,1:2));
end
% Determinar a maior Correlação em módulo
CorrMin=min(Corr(:,2));
CorrMax=max(Corr(:,2));
[Corrmax,D]=max(CorrAbs(:,2));

```

```

D=Corrmax;

% Passo 03: Gerar Janela de Dados de Experiência, Aplicando Deslocamento
% com Maior Correlação nos Dados -----
nA7=nA6-InA;
A7=[A6(InA:InA+nA7-1,1:2)];
B7=[B6(InB-D:InB-D+nA7-1,1:2)];

% Passo 04: Vetor Variações dos Dados -----
nA7=size(A7,1);
for i=1:nA7-1
    VA(i,1:2)=[A7(i+1,1),abs(A7(i+1,2)-A7(i,2))];
    VB(i,1:2)=[B7(i+1,1),abs(B7(i+1,2)-B7(i,2))];
end
MVA=max(VA(:,2));
MVB=max(VB(:,2));

% Passo 05: Carregar Controlador Fuzzy (Pacote do MatLab)-----
% Obs.: As funções Pertinências são automatizadas em função do
% MVA e MVB.
F=readfis('ControleFuzzy');
F.input(1).range=[0 5*MVB];
F.input(1).mf(1).params=[0 0 MVB/2];
F.input(1).mf(2).params=[0 MVB/2 MVB];
F.input(1).mf(3).params=[MVB/2 MVB 5*MVB 5*MVB];
F.input(2).range=[0 5*MVA];
F.input(2).mf(1).params=[0 0 MVA/2];
F.input(2).mf(2).params=[0 MVA/2 MVA];
F.input(2).mf(3).params=[MVA/2 MVA 5*MVA 5*MVA];

% Passo 06: Equiparar medidas do Evento Ei com Temperatura através do número de
% elementos e da defasagem (D) -----
if A6(1,1)<=B6(1,1)+D*7
    InA2=find(A6==B6(1,1)+D*7);
    A8=[A6(InA2:nA6,1:2)];
    B8=[B6(1:nA6-InA2+1,1:2)];
    for i=1:nPM
        if PM(i)-(InA2-1)<=0;
            PM(i)=1;
        else
            PM(i)=PM(i)-(InA2-1);
        end
    end
else
    InB2=find(B5==A6(1,1)-D*7);
    A8=A6;
    B8=[B6(InB2:InB2+nA6-1,1:2)];
end

% Passo 07: Níveis de Alertas apenas para pontos detectados -----
nA8=size(A8,1);
for i=1:nA8-1
    VAT(i,1:2)=[A8(i+1,1),abs(A8(i+1,2)-A8(i,2))];
    VBT(i,1:2)=[B8(i+1,1),abs(B8(i+1,2)-B8(i,2))];
end
for i=1:nA8-1
    NAT(i,1:2)=[VAT(i,1),1/6];
end
for i=1:nPM
    NAT(PM(i),2)=evalfis([VBT(PM(i),2) VAT(PM(i),2)],F));
end

% Passo 08: Apresentação dos Resultados (Gráfico Colorido)-----
n=size(NAT,1);
In=find(NAT==35435);
a1=mean(NAT(In:n,2))+2*std(NAT(In:n,2));
a2=mean(NAT(In:n,2))+4*std(NAT(In:n,2));

```

```

subplot(2,1,1);
hold on
for i=1:nA8-1
    if NAT(i,2)<=a1
        line([A8(i,1)+693960,A8(i+1)+693960],[A8(i,2),A8(i+1,2)], 'Color',[0 1
0], 'LineWidth',2)
    elseif (NAT(i,2)>a1) && (NAT(i,2)<= a2)
        line([A8(i,1)+693960,A8(i+1)+693960],[A8(i,2),A8(i+1,2)], 'Color',[1 1
0], 'LineWidth',2)
    else
        line([A8(i,1)+693960,A8(i+1)+693960],[A8(i,2),A8(i+1,2)], 'Color',[1 0
0], 'LineWidth',2)
    end
end
hold off

%-----

```

APÊNDICE 7: ALGORITMO PARA A ANÁLISE *FUZZY* DE ÁRVORE DE FALHAS

Algoritmo para a aplicação de uma análise *fuzzy* de árvore de falhas, baseado no conjunto de cortes mínimos definidos na Seção 2.9.4, programado no *software* MATLAB R2013A.

```

% Análise Fuzzy de Árvore de Falhas
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: FFTA

clear;
clc;

% Passo 01: Carregar Dados -----
N=xlsread('MatrizNFA.xls'); % Matriz com a Data e Níveis Fuzzy de Alerta
                             % de cada Evento Básico
n=size(N,1);

% Passo 02: Cálculo do Nível Fuzzy de Alerta do Evento Topo -----
for i=1:n
    C1(i,1)=min(N(i,5),N(i,6));
    C2(i,1)=min(N(i,5),N(i,7));
    C3(i,1)=min(N(i,5),N(i,8));
    C4(i,1)=min([N(i,2),N(i,3),N(i,4),N(i,5)]);
    M(i,1)=max([C1(i,1),C2(i,1),C3(i,1),C4(i,1)]);
    NT(i,1:2)=[N(i,1),M(i,1)];
end

% Passo 03: Apresentação dos Resultados (Gráfico Colorido) -----
In=find(NT==35435);
a1=mean(NT(In:n,2))+2*std(NT(In:n,2));
a2=mean(NT(In:n,2))+3*std(NT(In:n,2));
subplot(2,1,1);
hold on
k1=1;
k2=1;
for i=2:n
    if NT(i,2)<=a1

```

```

        line([NT(i-1,1)+693960,NT(i)+693960],[NT(i-1,2),NT(i,2)], 'Color',[0 1
0], 'LineWidth',2)
    elseif (NT(i,2)>a1) && (NT(i,2)<= a2)
        line([NT(i-1,1)+693960,NT(i)+693960],[NT(i-1,2),NT(i,2)], 'Color',[1 1
0], 'LineWidth',2)
        AA(k1)=i;
        k1=k1+1;
    else
        line([NT(i-1,1)+693960,NT(i)+693960],[NT(i-1,2),NT(i,2)], 'Color',[1 0
0], 'LineWidth',2)
        AV(k2)=i;
        k2=k2+1;
    end
end
end

xlswrite('NT',NT);          % Níveis Fuzzy de Alerta do Evento Topo
xlswrite('AA',AA);          % Pontos com Nível de Atenção Amarelo
xlswrite('AV',AV);          % Pontos com Nível de Atenção Vermelho

% -----

```

APÊNDICE 8: ALGORITMO PARA O CÁLCULO DA MEDIDA DE IMPORTÂNCIA

Algoritmo para o cálculo da medida de importância de cada evento básico, programado no *software* MATLAB R2013A.

```

% Medida de Importância Fuzzy
% Fernando Bando (Tese de Doutorado - 2016)
% Nome: MIF

clear;
clc;

% Passo 01: Carregar Dados -----
MN=xlsread('MatrizNFA.xls');    % Matriz com a Data e Níveis Fuzzy de Alerta
                                % de cada Evento Básico
NT=xlsread('NT.xls');           % Níveis Fuzzy de Alerta do Evento Topo
AA=xlsread('AA.xls');           % Pontos com Nível de Atenção Amarelo
AV=xlsread('AV.xls');           % Pontos com Nível de Atenção Vermelho
n=size(NT,1);

% Passo 02: Cálculo da Medida De Importância para cada data -----
for i=1:n;
    for j=1:7
        N(1,1:7)=MN(i,2:8);
        N(j)=0.1667;
        C1=min(N(4),N(5));
        C2=min(N(4),N(6));
        C3=min(N(4),N(7));
        C4=min([N(1),N(2),N(3),N(4)]);
        N0=max([C1,C2,C3,C4]);
        FV(j)=(NT(i,2)-N0)/NT(i,2);
    end
end

% Passo 03: Apresentação dos Eventos mais importantes em ordem de
% importância -----
for j=1:7
    O(j,1:2)=[j,FV(j)];
end

```

```

for h=1:7
no=size(O,1);
m=1;
    for k=1:no
        if O(k,2)>O(m,2)
            m=k;
        end
    end
    Evento(1,h)=O(m,1);
    O(m,:)=[];
end
MIT(i,1:16)=[NT(i,1:2),FV,Evento];
end

xlswrite('PrincipaisEventos',MIT);

% Eventos do Alarme Amarelo
na=size(AA,2);
for i=1:na
    MIamarelo(i,1:16)=MIT(AA(i),1:16);
end

% Eventos do Alarme Vermelho
nv=size(AV,2);
for i=1:nv
    MIvermelho(i,1:16)=MIT(AV(i),1:16);
end

%-----

```

ANEXO

ANEXO 1: ÁRVORE DE FALHAS DO BLOCO D38 DA BARRAGEM DE ITAIPU

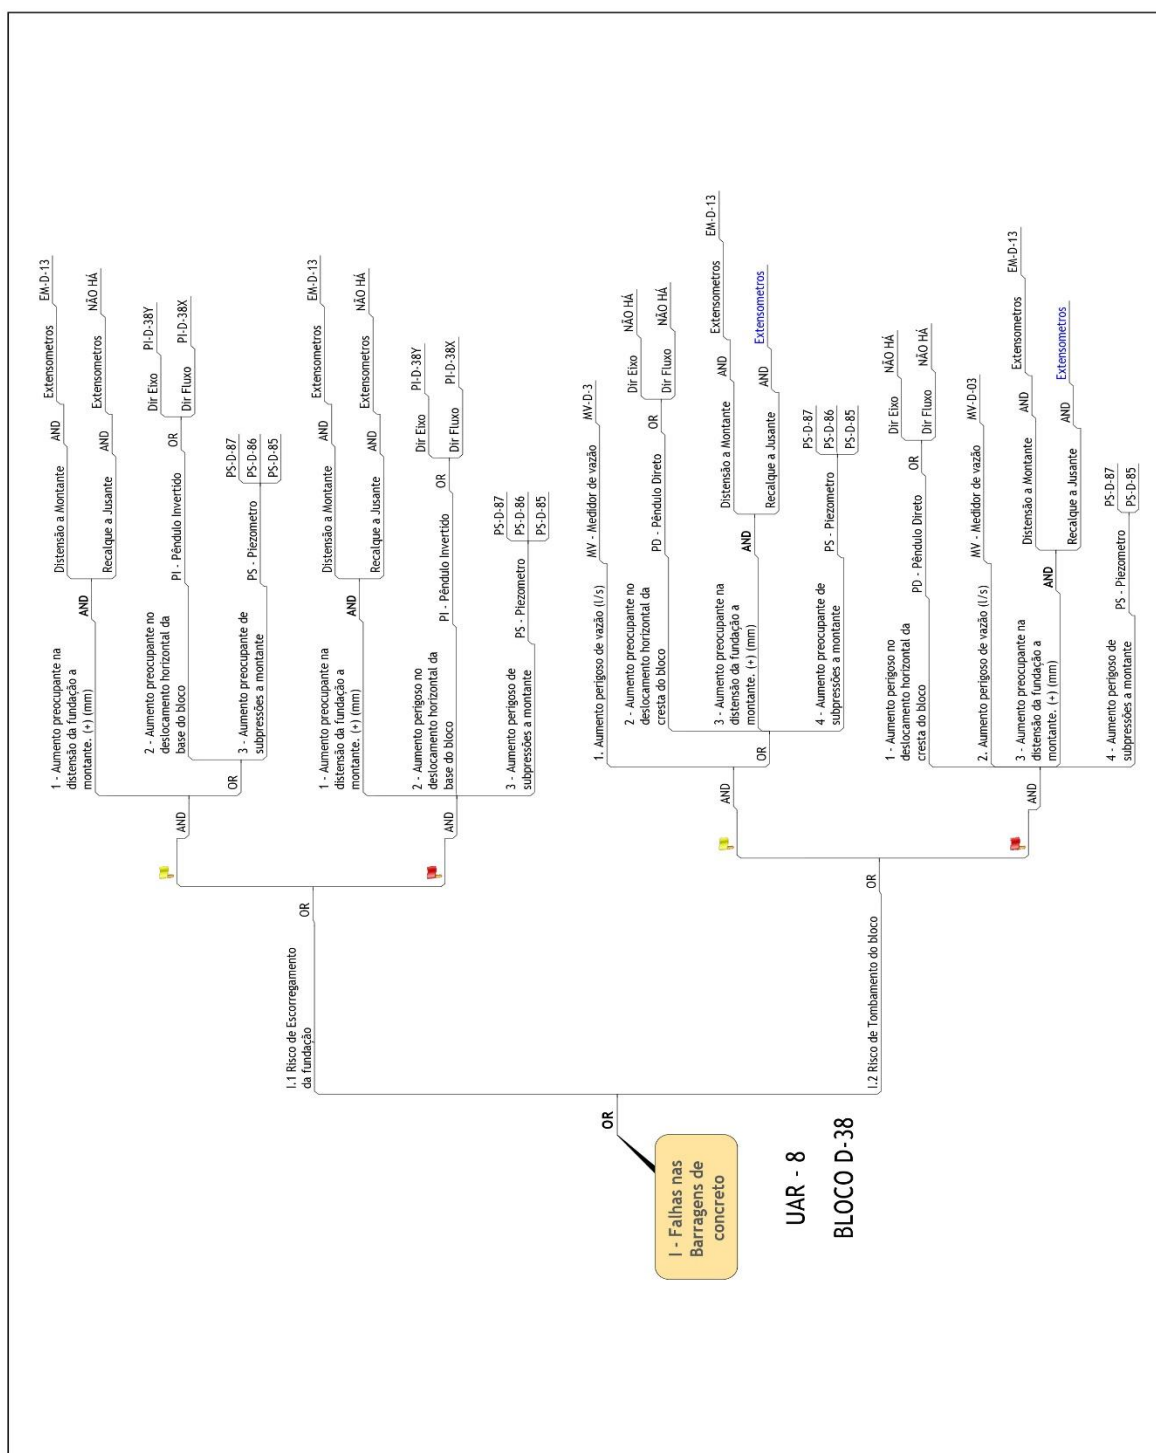


FIGURA 6.1 – Árvore de Falhas construída por especialistas em segurança de barragens para o bloco de contraforte D38 da Barragem de Itaipu

FONTE: Acervo Itaipu Binacional (2015)